



Diogo Correia Moniz Lemos

Licenciado em Ciências de Engenharia e Gestão Industrial

Proposta de metodologia de apoio ao agendamento de uma oficina autorizada da SIVA. Caso de estudo

Dissertação para Obtenção do Grau de Mestre em Engenharia e
Gestão Industrial

Orientadora: Professora Doutora Ana Paula Barroso
Professora Auxiliar, FCT-UNL

Coorientadora: Professora Doutora Virgínia Helena Arimateia de
Campos Machado
Professora Auxiliar, FCT-UNL

Júri:

Presidente: Professor Doutor Rogério Salema Araújo Puga Leal
Coordenador do MIEGI, FCT-UNL

Vogais: Professor Doutor Nuno Alexandre Correia Martins Cavaco
Professor Auxiliar, FCT-UNL

Professora Doutora Ana Paula Barroso
Professora Auxiliar, FCT-UNL

Engenheiro Pedro Miguel Vieira Prazeres
Diretor do Serviço Após Venda, SIVA



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

setembro de 2016

Proposta de metodologia de apoio ao agendamento de uma oficina autorizada da SIVA.
Caso de estudo

Copyright ©: Diogo Correia Moniz Lemos, Universidade Nova de Lisboa – Faculdade de Ciências e Tecnologia

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

Agradecimentos

À Faculdade de Ciências e Tecnologia e a todas as pessoas que contribuíram para que este mestrado se concretizasse.

À Professora Ana Paula Barroso e à Professora Virgínia Helena Machado, orientadora e coorientadora, pelo apoio prestado, pelo rigor, pelo conhecimento transmitido e por toda a disponibilidade na concretização deste trabalho.

À SIVA, em especial à Direção do Serviço após Venda, onde foi possível desenvolver a minha dissertação. Agradeço em particular ao Eng.º Pedro Prazeres por todo o seu apoio, pela partilha de conhecimentos, pelas sugestões e comentários, pelas críticas e incentivos.

A todos os colaboradores do Departamento do Serviço após Venda, por toda a simpatia e a disponibilidade na partilha de conhecimentos e de informação.

À professora Carla Cunha agradeço a confiança.

Ao Gonçalo Pereira, pela amizade e companheirismo demonstrado ao longo do mestrado.

Aos meus amigos e colegas de curso, pelo especial contributo para a minha valorização académica e pessoal.

À minha irmã, por ser um modelo de dedicação e de organização, por todo o apoio, amizade e tolerância.

Aos meus pais, um agradecimento especial, pelo apoio incondicional, pela dedicação absoluta e pela vontade em proporcionar-me as condições necessárias em todas as etapas da minha vida.

Resumo

No serviço após venda do setor automóvel, uma organização oficial eficaz, nomeadamente através de métodos de gestão operacional que contribuem para a melhoria contínua dos seus processos, revela-se essencial para a consolidação da competitividade. Nesse sentido, a melhoria do processo de agendamento dos trabalhos diários de uma oficina pode conduzir i) a um aumento da rentabilidade, ii) a um aumento da satisfação do cliente, iii) à agilização dos recursos e iv) a maior rigor no planeamento da capacidade do serviço.

Os modelos de previsão surgem como ferramenta de apoio na tomada de decisão em atividades de gestão, nomeadamente, no planeamento dos recursos, da capacidade e da produção.

A presente dissertação foi desenvolvida na empresa SIVA – Sociedade de Importação de Veículos Automóveis, S.A., com vista à análise e melhoria do agendamento das operações de mecânica da oficina autorizada do concessionário Soauto Expo. Como se trata do primeiro estudo desenvolvido na empresa neste âmbito, considerou-se necessário implementar o ciclo PDCA (*Plan-Do-Check-Act*) na análise do desempenho do serviço de assistência técnica da oficina, com base no agendamento em vigor no concessionário, para i) definir e explicar os dados a recolher, ii) medir e analisar o desempenho da oficina e, por fim, iii) propor uma alteração no sentido da melhoria contínua do seu desempenho.

Assim, nesta dissertação é proposta uma metodologia de apoio ao agendamento da oficina que tem por base a adoção de um modelo de previsão das necessidades diárias de utilização de horas-homem (número de horas trabalhadas pelos técnicos) para clientes sem marcação prévia. O modelo de previsão selecionado, o modelo de *Holt-Winters*, modela a sazonalidade semanal, identificada na etapa de análise do histórico das necessidades diárias de utilização de horas-homem.

A metodologia de agendamento proposta apresentou maior precisão e uma redução das estatísticas do erro de previsão relativamente ao processo de agendamento atualmente em vigor. Verificou-se uma redução de 280 horas-homem no total da magnitude do erro de previsão da amostra de validação, que significa uma redução do número de horas improdutivas.

Palavras-chave: serviço após venda, planeamento, agendamento, ciclo PDCA, modelos de previsão.

Abstract

In the after sales car service sector, an effective car repair shop service organization, in particular through operational management methods which contribute to the continuous improvement of its processes, is essential for the consolidation of competitiveness. In that sense, the improvement of the daily work scheduling process in a car repair shop can drive to i) an increased profitability, ii) an increase of customer satisfaction, iii) the streamlining of resources and iv) a greater rigour in the service's capacity planning.

The forecasting models emerge as a tool to support decision-making in management activities, namely, in the planning of resources, capacity and production.

This dissertation was developed in the company SIVA - Sociedade de Importação de Veículos Automóveis, S.A., with the purpose of analysing and improving the scheduling of mechatronics operations of the authorized dealer car repair shop, Soauto Expo. As this is the first study of the kind developed in the company, it was considered necessary to implement the PDCA cycle in the analysis of the performance of the car repair shop service, based on the existing dealer schedule, to i) define and explain the data which is supposed to be collected, ii) to measure and analyse the car repair shop performance, and finally (iii) propose a change in direction of the continuous improvement of its performance.

Thus, this dissertation proposes a methodology to support the schedule of car repair shop that is based on the adoption of a forecasting model of the daily needs of use of man-hours (number of hours worked by the technicians) to customers without prior appointment. The selected forecasting model, the model of Holt-Winters, models the weekly seasonality, identified in the analysis stage of the daily needs background for the use of man-hours.

The schedule proposed methodology has shown greater accuracy and a reduction in forecast error statistics regarding the scheduling process currently in place. There was a reduction of 280 man-hours in the total magnitude of the validation of the sample forecast error, which represents a reduction of unproductive hours.

Keywords: after-sales service, operations management, scheduling, PDCA cycle, forecasting models.

Lista de Abreviaturas

GQT – Gestão pela Qualidade Total

JIT – *Just in Time*

PDCA – *Plan-Do-Check-Act*

EM – Erro Médio

EA – Erro Absoluto

EAM – Erro Absoluto Médio

EPAM – Erro Percentual Absoluto Médio

EQ – Erro Quadrático

REQM – Raiz do Erro do Erro Quadrático Médio

AES – Alisamento Exponencial Simples

ARIMA – *Autoregressive Integrated Moving Average*

(Modelo Autoregressivo integrado de médias móveis)

SARIMA – *Seasonal Autoregressive Integrated Moving Average*

(Modelo sazonal autoregressivo integrado de médias móveis)

AIC – Critério de Informação de Akaike

H.h – Horas-homem

CSS – *Customer Satisfaction Survey*

DMS – Sistema de Gestão dos Concessionários

DISS – Serviço de Sistema de Informação Direta

Índice de Conteúdos

Capítulo 1 - Introdução.....	1
1.1. Enquadramento	1
1.2. Motivação.....	2
1.3. Objetivo.....	2
1.4. Metodologia	3
1.5. Estrutura da Dissertação.....	4
Capítulo 2 – Fundamentação Teórica	7
2.1. Introdução à Gestão de Operações	7
2.1.1. Enquadramento.....	7
2.1.2. Tarefas da Gestão nas Operações.....	8
2.1.2.1. Medição do Desempenho Operacional.....	11
2.2. Ciclo PDCA	12
2.3. Modelos de Previsão	14
2.3.1. A Previsão como Suporte ao Planeamento.....	14
2.3.2. Métodos de Previsão	15
2.3.3. Processo de Implementação de Modelos de Previsão	16
2.3.4. Série Cronológica.....	18
2.3.4.1. Componentes.....	18
2.3.4.2. Tratamento Estatístico.....	20
2.3.4.3. Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACP).....	21
2.3.4.4. Coeficiente de Correlação	23
2.3.5. Precisão da Previsão.....	25
2.3.5.1. Medidas Estatísticas Standard	25
2.3.5.2. Comparação e Critério de Seleção dos Modelos	26
2.3.5.3. Intervalo de Previsão	27
2.3.6. Modelos de Previsão Quantitativos.....	27
2.3.6.1. Alisamento Exponencial Simples.....	27
2.3.6.2. Holt-Winters.....	28
2.3.6.3. ARIMA	30
2.3.6.3.1. Modelos para séries estacionárias	31
2.3.6.3.2. Modelos para séries não estacionárias.....	33
2.3.6.3.3. Verificação do modelo	34
2.3.6.3.4. Critério de seleção dos modelos ARIMA.....	35
2.3.6.4. Regressão Linear Múltipla	35
2.3.6.4.1. Variáveis explicativas relacionadas com o tempo.....	35
2.3.6.4.2. Análise da variabilidade	36

Capítulo 3 - Contextualização do Caso de Estudo	39
3.1. Caracterização da Empresa	39
3.1.1. Grupo SAG – Soluções Automóvel Globais	39
3.1.2. SIVA – Sociedade de Importação de Veículos Automóveis, SA	40
3.1.3. Concessionários Soauto	41
3.1.3.1. Processos Base do Serviço de Assistência Técnica	42
3.1.3.2. Importância do Agendamento para o Serviço de Assistência Técnica	45
3.2. Descrição do Caso de Estudo	46
3.2.1. Agenda Oficial	47
3.2.1.1. Primeira Fase do Agendamento – Definição de Objetivos	48
3.2.1.2. Segunda Fase do agendamento – Marcações e Planeamento dos Recursos	49
3.2.1.3. Realização dos Trabalhos de Manutenção e Reparação	51
3.2.1.4. Agendamento versus Realização	52
3.2.2. Fonte de Dados e Descrição das Variáveis	54
3.2.3. Desempenho Atual da Oficina Soauto Expo	55
3.2.3.1. Taxa de Ocupação	55
3.2.3.2. Taxa de Utilização para cada tipo de “Estado”	56
3.2.3.3. Eficácia do Agendamento	59
3.2.3.4. Conclusão	61
Capítulo 4 – Proposta de uma Metodologia de Apoio ao Agendamento e Análise de Resultados	63
4.1. Identificação de Oportunidades de Melhoria	63
4.2. Processo	64
4.2.1. Objetivos do Modelo de Previsão	65
4.2.2. Horizonte Temporal e Recolha de Dados	66
4.2.3. Tratamento dos Dados	67
4.3. Análise da Série Cronológica	69
4.4. Modelos de Previsão a Analisar	71
4.5. Etapa de Ajustamento	73
4.5.1. Modelo Alisamento Exponencial Simples com Sazonalidade	73
4.5.2. Modelo de <i>Holt-Winters</i>	75
4.5.3. Modelo SARIMA	76
4.5.4. Modelo de Regressão Linear Múltipla	81
4.6. Etapa de Validação	89
4.6.1. Modelo de Regressão Linear Múltipla	90
4.6.2. Modelo de <i>Holt-Winters</i>	91
4.7. Avaliação dos Modelos	92

4.8. Proposta de Metodologia de Apoio ao Agendamento de uma Oficina	95
Capítulo 5 – Conclusões e Propostas para Desenvolvimento Futuro	99
5.1. Principais conclusões	99
5.1.1. Importância do Agendamento	99
5.1.2. Desempenho Atual da Oficina em Estudo	99
5.2. Propostas para Desenvolvimento Futuro.....	102
Referências Bibliográficas	105
Anexos	109
Anexo I – Tabelas Estatísticas	109
Anexo II – Análise de Resultados	109

Índice de Figuras

Figura 1.1 – Estrutura da dissertação.	6
Figura 2.1 – Desafios para a gestão nos serviços de atendimento.....	10
Figura 2.2 – Ciclo PDCA	13
Figura 2.3 – Processo de Implementação de modelos de previsão.	17
Figura 2.4 – Função de autocorrelação de uma série com sazonalidade e função de autocorrelação de uma série não estacionária, em média.	22
Figura 3.1 – Áreas de negócio do Grupo SAG – Soluções Automóvel Globais.....	40
Figura 3.2 – Processos base do serviço de manutenção e reparação.....	42
Figura 3.3 – Fase de classificação dos tipos de ordem de reparação.	44
Figura 3.4 – Processos base do serviço de manutenção e reparação envolvidos na agenda oficial.	48
Figura 3.5 – 1ª Fase do agendamento – Definição dos objetivos.....	49
Figura 3.6 – 2ª Fase do agendamento – Marcações e planeamento dos recursos.....	50
Figura 3.7 – Processos base do serviço de manutenção e reparação na definição e preparação das operações diárias na oficina.	51
Figura 3.8 – Fluxos gerados na definição e preparação das operações diárias na oficina.....	51
Figura 3.9 – Esquema da segmentação das horas trabalhadas pelos técnicos por tipos de utilização (“estado”).	52
Figura 3.10 – Representação esquemática da metodologia da agenda oficial.....	53
Figura 3.11 – Ocupação média mensal dos técnicos da oficina Soauto Expo entre Fevereiro de 2014 e Março de 2016.....	56
Figura 3.12 – Percentagem média anual dos quatro tipos de horas trabalhadas pelos técnicos e da improdutividade entre 2014 e 2016.....	58
Figura 3.13 – Percentagem média mensal da utilização dos técnicos nos quatro tipos de “estado” e da improdutividade entre Fevereiro de 2014 e Março de 2016.....	58
Figura 3.14 – Percentagem média por dia da semana dos quatro tipos de horas trabalhadas pelos técnicos e da improdutividade.....	59
Figura 3.15 – Eficácia do agendamento em termos mensais.....	60
Figura 4.1 – Metodologia utilizada no desenvolvimento do modelo de previsão.....	65
Figura 4.2 – Proposta de metodologia de apoio ao agendamento.	66
Figura 4.3 – Definição da amostra de ajustamento e de validação.	67
Figura 4.4 – Série cronológica da utilização de H.h para clientes sem marcação.....	67
Figura 4.5 – Outliers identificados na série cronológica (sem os valores nulos) através do teste Box-plot.....	68

Figura 4.6 – Série cronológica da utilização de H.h para clientes sem marcação – amostra de ajustamento.	69
Figura 4.7 – Função de autocorrelação da série cronológica (amostra de ajustamento – 4,3% dos dados modificados).	70
Figura 4.8 – Função de autocorrelação da série cronológica (amostra de ajustamento – 4,3% dos dados modificados) com diferenciação de 1ª ordem.	71
Figura 4.9 – Tipo de amostra de ajustamento para os modelos a analisar.	72
Figura 4.10 – Série cronológica da utilização de H.h para clientes sem marcação – amostra de validação.	72
Figura 4.11 – Valores reais da amostra de ajustamento e valores estimados pelo modelo AES com sazonalidade ($\alpha=0,195$).	74
Figura 4.12 – Valores reais da amostra de ajustamento e valores estimados pelo modelo Holt-Winters ($\alpha=0,099$; $\beta=0$; $\gamma=0,119$).	76
Figura 4.13 – FAC e FACP da série de ajustamento.	77
Figura 4.14 – FAC e FACP da série de ajustamento com diferenciação de 1ª ordem.	78
Figura 4.15 – FAC e FACP da série de ajustamento com diferenciação de 1ª ordem e 5ª ordem.	78
Figura 4.16 – Função de autocorrelação dos resíduos do modelo SARIMA(1,1,1)(0,1,1) ₅	80
Figura 4.17 – Valores reais da amostra de ajustamento e valores estimados pelo modelo SARIMA(1,1,1)(0,1,1) ₅	81
Figura 4.18 – Utilização média por mês de H.h para clientes sem marcação entre Fevereiro de 2014 a Março de 2016 na oficina autorizada Soauto Expo.	84
Figura 4.19 – Valores reais da amostra de ajustamento e valores estimados pelo modelo regressão linear múltipla (modelo 3).	89
Figura 4.20 – Valores reais da amostra de validação e valores previstos pelo modelo de regressão linear múltipla (modelo 3).	91
Figura 4.21 – Valores reais da amostra de validação e valores previstos pelo modelo Holt-Winters ($\alpha=0,099$; $\beta=0$; $\gamma=0,119$).	92
Figura II.1 – Resultados obtidos do ajuste do modelo SARIMA(0,1,1)(0,1,1) ₅ à série de ajustamento através do software Minitab.	110
Figura II.2 – Resultados obtidos do ajuste do modelo SARIMA(1,1,1)(1,1,1) ₅ à série de ajustamento através do software Minitab.	110
Figura II.3 – Resultados obtidos do ajuste do modelo SARIMA(1,1,1)(0,1,2) ₅ à série de ajustamento através do software Minitab.	111
Figura II 4 – Resultados obtidos do ajuste do modelo SARIMA(1,1,1)(0,1,1) ₅ à série de ajustamento através do software Minitab.	111

Índice de Tabelas

Tabela 2.1 – Efeitos da elevada interação com os clientes nas atividades de gestão.	11
Tabela 2.2 - Descrição do padrão teórico apresentado nas funções de autocorrelação e de autocorrelação parciais para um modelo AR(p), MA(q) e ARMA(p,q).	33
Tabela 2.3 – Tabela de análise da variância (ANOVA).	37
Tabela 3.1 – Tipos de ordem de reparação.	45
Tabela 3.2 – Dados recolhidos e a respetiva descrição.	54
Tabela 4.1 – Resultados obtidos no ajuste do modelo AES com sazonalidade.	74
Tabela 4.2 – Teste do Bias ao erro médio (AES com sazonalidade; etapa de ajustamento).	74
Tabela 4.3 – Resultados obtidos do ajuste do modelo Holt-Winters.	75
Tabela 4.4 – Teste do Bias ao erro médio (Holt-Winters; etapa de ajustamento).	75
Tabela 4.5 – Resultados obtidos no ajuste de modelos SARIMA à amostra de ajustamento.	78
Tabela 4.6 – Resultados obtidos do ajuste do modelo SARIMA(1,1,1)(0,1,1) ₅	80
Tabela 4.7 – Teste do Bias ao erro médio (ARIMA; etapa de ajustamento).	80
Tabela 4.8 – Análise de correlação de variáveis quantitativas.	82
Tabela 4.9 – Variáveis “dummy” consideradas no modelo de regressão linear múltipla.	85
Tabela 4.10 – Resultados obtidos do ajustamento de 3 modelos de regressão linear múltipla. ..	87
Tabela 4.11 – Análise da variância do modelo de regressão linear múltipla (modelo 3).	88
Tabela 4.12 – Resultados obtidos do ajuste do modelo de regressão linear múltipla (modelo 3).	88
Tabela 4.13 – Teste do Bias ao erro médio (Regressão linear múltipla, modelo 3; etapa de ajustamento).	88
Tabela 4.14 – Resultado da capacidade preditiva do modelo de regressão linear múltipla (modelo 3) para a amostra de validação.	90
Tabela 4.15 – Teste do Bias ao erro médio (Regressão linear múltipla, modelo 3; etapa de validação).	90
Tabela 4.16 – Resultados obtidos da aplicação do modelo Holt-Winters na amostra de validação.	91
Tabela 4.17 – Teste do Bias ao erro médio (Holt-Winters; etapa de validação).	91
Tabela 4.18 – Quadro síntese dos resultados obtidos na etapa de ajustamento e o alcance de previsão em cada um dos modelos estudados.	92
Tabela 4.19 – Quadro síntese dos resultados obtidos na etapa de validação para os modelos de regressão linear múltipla e Holt-Winters.	93
Tabela 4.20 – Resultados na etapa de validação: Metodologia de agendamento proposta vs. Metodologia de agendamento atual.	95

Tabela 4.21 – Metodologia de apoio ao agendamento das operações de mecânica de uma oficina de reparação automóvel - Proposta	96
Tabela I.1 – Valores críticos da distribuição normal reduzida.	109
Tabela II.2 – Teste Box-plot aplicado aos valores extremos.	109
Tabela II.3 – Teste Box-plot aplicado às diferenças sazonais.	109

Capítulo 1 - Introdução

O presente trabalho, no âmbito da unidade curricular Dissertação do Mestrado em Engenharia e Gestão Industrial, foi desenvolvido na empresa SIVA – Sociedade de Importação de Veículos Automóveis, SA – no departamento do serviço após venda, com vista à análise e melhoria do agendamento dos trabalhos da oficina autorizada Soauto Expo – serviço assistência técnica Audi e Volkswagen –, que se dedica à manutenção e reparação de veículos automóveis e à prestação de serviços conexos.

Neste primeiro capítulo pretende-se enquadrar a dissertação na realidade empresarial e dos mercados atuais e apresentar o que motivou o desenvolvimento do tema, os objetivos a atingir e a metodologia utilizada para alcançar os referidos objetivos. Por fim, é explicitada a estrutura da dissertação de maneira a fornecer uma noção geral das temáticas abordadas.

1.1. Enquadramento

No atual ambiente de mercado concorrencial e dinâmico, as atividades do serviço após venda – que englobam a venda de serviços de manutenção e reparação e a venda de peças e acessórios – são reconhecidas como uma importante fonte de receita, lucro e vantagem competitiva nas indústrias do setor automóvel. Trata-se da área onde existe um contacto mais frequente com o cliente, o que faz com que apresente um conjunto de oportunidades de vendas e de melhoria dos seus processos.

Durante a prestação de um serviço, muitas são as influências e as perturbações que afetam o processo de entrega do serviço (Lagemann et al., 2013). Para tomar as decisões necessárias de modo a oferecer aos clientes um serviço de qualidade, uma empresa deve ver os seus processos de negócios para além dos limites funcionais e centra-se na melhoria contínua dos seus processos, tendo como foco o serviço prestado aos clientes e as prioridades competitivas estabelecidas pela organização (Finch e Luebbe, 1995).

Um método sistemático, muitas vezes usado para realizar a melhoria contínua, é o ciclo PDCA (*Plan-Do-Check-Act*) (Finch e Luebbe, 1995) desenvolvido por Deming. O ciclo encontra-se aliado a um esforço contínuo e permanente para alcançar melhorias mensuráveis na eficiência, na eficácia, na responsabilidade, nos resultados e noutros indicadores de qualidade em serviços ou processos (Gorenflo e Moran, 2010). Permite a definição de um plano de ação, medição e avaliação da execução do plano e, consequentemente, propor métodos, ações e/ou alterações nas atividades e operações de uma organização.

Neste contexto, surgem vários tipos de estudos no sentido de melhorar as operações de uma empresa. Os modelos de previsão são ferramentas estatísticas adotadas frequentemente no mundo dos negócios, sendo um dos suportes fundamentais na tomada de decisão quanto ao planeamento da produção, do transporte e da mão-de-obra. Assim, devem ser consideradas uma parte integrante tanto no apoio à tomada de decisão como nas atividades da gestão (Athanasopoulos e Hyndman, 2014).

1.2. Motivação

O principal desafio do estudo foi proposto pela direção do serviço após venda da SIVA, que apontou a necessidade de analisar e melhorar a metodologia de agendamento das operações de mecânica, atualmente em vigor, de uma das oficinas autorizadas, a Soauto Expo.

A adoção de uma excelente organização oficial, nomeadamente através i) do aprovisionamento das ferramentas necessárias à correta e eficiente realização do trabalho, ii) da eliminação de desperdícios, tais como deslocamentos desnecessários e tempo de espera por peças, e iii) de métodos apropriados de gestão operacional, como são os procedimentos e os diagramas de trabalho *standard*, revelam-se essenciais para a consolidação da competitividade.

Nesse sentido, o agendamento dos trabalhos diários numa oficina revela-se fundamental i) no planeamento da necessidade de recursos, da capacidade e correspondente disponibilidade para satisfazer a procura do serviço e ii) na programação das atividades de reparação/manutenção para que os técnicos operem corretamente e se reduza as atividades não produtivas, tanto em número como em duração.

As crescentes exigências que caracterizam o mercado atual e a consequente necessidade de desenvolver a melhoria contínua constituem a principal motivação para a realização da presente dissertação.

1.3. Objetivo

O objetivo principal da presente dissertação centra-se na conceção e no desenvolvimento de uma metodologia de agendamento das operações diárias de mecânica na Soauto Expo, uma das oficinas autorizadas da SIVA.

Para alcançar o objetivo principal é efetuada uma análise do desempenho do serviço de assistência técnica, com base no agendamento em vigor no concessionário Soauto Expo. Para além de ser um objetivo, é também necessário na implementação do ciclo PDCA para i) definir e explicar os dados a recolher, ii) medir e analisar o desempenho da oficina e, por fim, iii) propor

uma alteração no sentido da melhoria contínua do desempenho da oficina – o objetivo principal da presente dissertação mencionado no primeiro parágrafo desta secção. A aplicação do ciclo PDCA consiste no seguinte:

1. Definição dos dados a recolher;
2. Medição do desempenho;
3. Análise e identificação de potenciais causas e oportunidades de melhoria;
4. Identificação de proposta de melhoria no agendamento das operações diárias de mecânica da oficina.

Registam-se outros objetivos relevantes que se pretendem alcançar:

- Contextualizar teoricamente o caso de estudo no âmbito da gestão de operações, da melhoria contínua e dos modelos de previsão;
- Identificar, no futuro, possíveis trabalhos nesta área.

Em suma, para atingir o objetivo principal desta dissertação é i) realizada uma análise do agendamento das operações de mecânica e ii) identificada e avaliada uma oportunidade de melhoria, com base no ciclo PDCA e na implementação de um modelo de previsão.

1.4. Metodologia

A metodologia de agendamento das operações diárias de mecânica proposta tem por base a adoção de um modelo de previsão das necessidades diárias de utilização de horas-homem (número de horas trabalhadas pelos técnicos) para clientes sem marcação.

De forma a identificar o modelo que melhor se ajusta ao comportamento da variável, necessidades diárias de utilização de horas-homem para clientes sem marcação, são analisados vários modelos de previsão de séries cronológicas e causais, baseados no comportamento da variável ao longo do tempo e na influência de outras variáveis associadas ao agendamento (e limitado aos dados recolhidos). A análise permite avaliar a sua adequabilidade, as vantagens e as limitações no agendamento das operações de mecânica. Entre os vários desafios deste estudo, podem ser enumerados os seguintes:

1. Definir as amostras de ajustamento e de validação a usar no desenvolvimento do modelo de previsão;
2. Analisar o ajustamento de cada modelo de previsão relativamente à utilização diária necessária de horas-homem para clientes sem marcação (com base na amostra de ajustamento);
3. Efetuar a validação de cada modelo de previsão (com base na amostra de validação), a partir dos modelos obtidos na amostra de ajustamento;

4. Quantificar o erro de previsão, tanto para a amostra de ajustamento como para a de validação;
5. Identificar o modelo que apresenta a estatística R^2 mais elevada e maior viabilidade do ponto de vista operacional;
6. Efetuar uma análise de sensibilidade de modo a avaliar se a metodologia de agendamento proposta apresenta melhorias face à metodologia de agendamento atualmente em vigor na oficina Soauto Expo.

1.5. Estrutura da Dissertação

A estrutura utilizada no desenvolvimento desta dissertação no sentido de alcançar os objetivos propostos na secção 1.3. necessita que todas as fases de desenvolvimento se encontrem interligadas. Nesse sentido, são consideradas três etapas fundamentais que correspondem aos capítulos 2, 3 e 4, nomeadamente:

- **1ª Etapa:** Pesquisa científica do tema para fundamentar e apoiar as ações a propor e a explorar (Capítulo 2);
- **2ª Etapa:** Descrição do caso de estudo e aplicação da metodologia PDCA. Determinação do desempenho atual do serviço de assistência técnica e identificação de oportunidades de melhoria (Capítulo 4);
- **3ª Etapa:** Proposta de um modelo de previsão da utilização de horas-homem para clientes sem marcação, após a avaliação da aplicabilidade, das vantagens e das limitações da sua utilização de alguns modelos como apoio ao agendamento diário das operações de mecânica do concessionário Soauto Expo (Capítulo 4).

A dissertação encontra-se, assim, dividida em 5 capítulos distintos de maneira a facilitar a compreensão e leitura da mesma.

O Capítulo 1, Introdução, apresenta as considerações iniciais da dissertação, incluindo o enquadramento do tema, a justificação quanto à relevância do tema em causa, a enumeração dos objetivos e a descrição da metodologia seguida neste estudo.

O Capítulo 2, Fundamentação Teórica, apresenta os conceitos relacionados com as análises desenvolvidas no que diz respeito à gestão de operações, à melhoria contínua e aos modelos de previsão, com base na recolha bibliográfica efetuada em que foram utilizadas as palavras-chave i) serviço após venda, ii) planeamento, iii) agendamento, iv) ciclo PDCA, v) modelos de previsão.

O Capítulo 3, Caracterização do Caso de Estudo, apresenta o caso de estudo, onde consta a caracterização da empresa, na qual incide o presente estudo, a contextualização do problema e algumas análises preliminares, nomeadamente, a determinação do desempenho atual da oficina Soauto Expo.

O Capítulo 4, Proposta de uma Metodologia de Apoio ao Planeamento e Análise de Resultados, contém a componente prática da dissertação, assente numa metodologia de implementação de modelos de previsão. Por conseguinte, neste capítulo, efetua-se uma análise evolutiva dos resultados obtidos i) no estudo preliminar da série cronológica, utilização de H.h para clientes sem marcação, e ii) nas etapas de ajustamento e de validação dos modelos de previsão.

O Capítulo 5, Conclusões e Propostas para Desenvolvimento Futuro, apresenta as conclusões finais do trabalho, as limitações dos modelos utilizados, as recomendações para possíveis ações de controlo e de melhoria e, ainda, as propostas de trabalhos futuros neste âmbito.

A Figura 1.1 apresenta de forma sistematizada a metodologia adotada para o desenvolvimento do presente projeto de investigação, bem como a localização de cada uma das fases de estudo na dissertação.

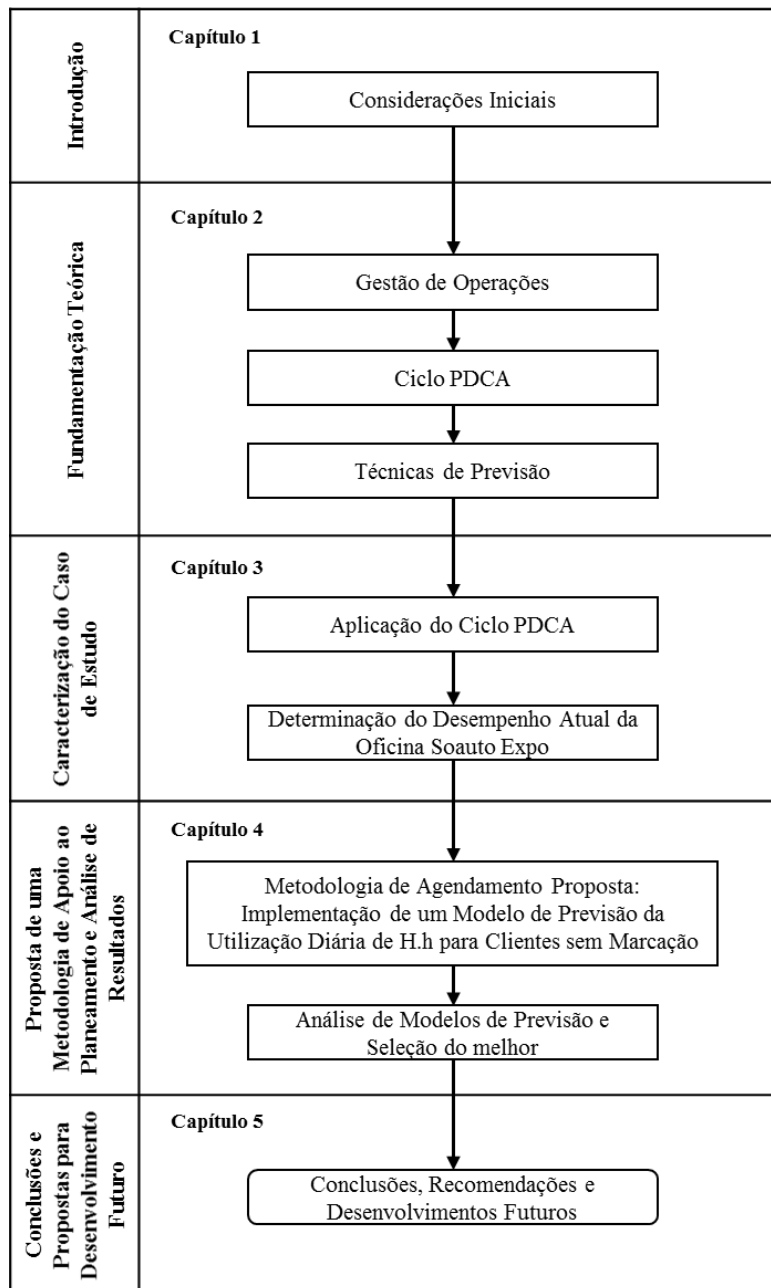


Figura 1.1 – Estrutura da dissertação.

Capítulo 2 – Fundamentação Teórica

O ponto de partida deste Capítulo consiste numa visão global i) de um sistema operativo e da sua função e ii) das tarefas de gestão e da sua importância num sistema operativo. Segue-se uma abordagem do serviço após venda, designadamente do serviço de reparação e manutenção automóvel, sobre i) os fatores que influenciam o serviço, ii) as atividades mais afetadas, iii) os desafios da sua gestão e iv) a temática relacionada com a medição do desempenho operacional. Depois é efetuado um enquadramento teórico do ciclo PDCA (*Plan-Do-Check-Act*), salientando a importância da sua implementação na melhoria contínua das atividades de uma empresa.

Como ferramenta de apoio na tomada de decisão em atividades de gestão, nomeadamente, no planeamento, efetua-se uma abordagem teórica dos modelos de previsão relativamente i) à sua importância no apoio ao planeamento, ii) ao seu processo de implementação, iii) aos comportamentos que se podem identificar na série cronológica a modelar, iv) à avaliação de desempenho e v) aos modelos utilizados nesta dissertação, de acordo com os vários modelos disponíveis.

2.1. Introdução à Gestão de Operações

2.1.1. Enquadramento

As operações, tal como a engenharia, a contabilidade, o marketing, a gestão de recursos humanos e as compras, são uma função de negócio. Num negócio, a função das operações passa pela gestão dos recursos necessários para produzir um produto ou serviço, incluindo recursos humanos, instalações, inventário, processos e sistemas (Finch e Luebbe, 1995).

Portanto, um sistema operacional é uma concertação de recursos combinados para o fornecimento de bens ou serviços, cuja função é a de satisfazer o cliente, isto é, fornecer alguma utilidade para o cliente (Wild, 2003).

Nesse sentido, os gestores de operações estão preocupados, principalmente, com a utilização dos recursos físicos que, por conveniência, são classificados da seguinte forma (Wild, 2003):

- Materiais: itens físicos consumidos ou convertidos pelo sistema, por exemplo, matérias-primas, combustíveis, materiais indiretos.
- Máquinas: itens físicos utilizados pelo sistema, por exemplo, plantas, ferramentas, veículos, edifícios.

- **Mão-de-obra:** recurso humano que contribui para o funcionamento do sistema, sem este recurso nem as máquinas nem os materiais são efetivamente utilizados.

A função de um sistema operativo é um reflexo do efeito que produz no seu cliente, isto é, a utilidade do seu *output* (saída) para o cliente (Wild, 2003). Podem ser identificadas quatro funções principais de um sistema operativo (Galloway, 1996; Wild, 2003):

- **Produção:** algo que é criado fisicamente, isto é, a saída é constituída por produtos que diferem fisicamente, em forma ou conteúdo, dos materiais de entrada para o sistema. Requer alguma transformação física dos materiais.
- **Transporte:** em que a principal característica é a circulação de mercadorias ou clientes, de um lugar para outro sem qualquer alteração física. Não existe uma grande mudança na forma dos recursos e o sistema fornece, essencialmente, uma mudança de localização;
- **Abastecimento:** em que a principal característica diz respeito à alteração da propriedade ou posse de bens. Não há nenhuma transformação física e a função do sistema é, essencialmente, uma mudança de utilidade na posse de um recurso;
- **Serviço:** tratamento ou alojamento de algo ou alguém. Ao contrário dos sistemas de abastecimento, o estado ou condição de saídas físicas será diferente das entradas em virtude de ter sido tratado de alguma forma.

Historicamente, o termo gestão de operações tem sido desenvolvido a partir de um alargamento do conceito de gestão de produção que, como o nome indica, preocupava-se, principalmente, com a gestão da conversão de matérias-primas em produtos acabados para a sua venda. Como se tornou evidente, muitas das técnicas desenvolvidas na produção foram igualmente aplicáveis à administração e ao setor de serviços. A terminologia evoluiu, assim, para gestão de operações de produção, gestão da produção e operações, operações de serviços e, finalmente, apenas gestão de operações (Galloway, 1996).

A gestão de operações preocupa-se com o *design* e a operação de sistemas de produção, de transporte, de abastecimento e/ou de serviço (Wild, 2003).

2.1.2. Tarefas da Gestão nas Operações

A gestão nas operações tem 4 tarefas fundamentais i) organizar, ii) planear, iii) controlar e iv) melhorar. Estas tarefas fornecem os meios pelos quais os recursos – que recaem em 4 categorias i) processo, ii) *stocks*, iii) mão-de-obra e iv) instalações e equipamentos – são agrupados para formar capacidades que podem proporcionar à empresa i) vantagem competitiva, designadamente, no preço, na qualidade, na dependência, na flexibilidade e/ou no tempo de resposta, ii) lucro a curto e a longo-prazo e iii) a melhoria da sua quota de mercado (Finch e Luebbe, 1995).

As tarefas fundamentais para a gestão num sistema operativo são a organização, o planeamento, o controlo e a melhoria (Finch e Luebbe, 1995):

1. **Organizar:** a organização das operações, muitas vezes, destina-se à conceção dos processos e à implementação de sistemas – nomeadamente, sistemas de suporte à decisão, sistemas de informação e sistemas físicos, como equipamentos, infraestruturas, inventário e mão-de-obra – que trazem consistência e normas à ação de gestão. As três filosofias de gestão i) Gestão pela Qualidade Total (GQT), ii) *Just-In-Time* (JIT) e iii) Gestão das Restrições, fornecem normas para organizar a tomada de decisão e garantir que todos os aspetos de um negócio são geridos de forma consistente.
2. **Planear:** Os planos são os meios pelos quais as metas são cumpridas. Em alternativa conforme o sentido: Os bons planos definem como é que os objetivos podem ser alcançados, mesmo se surgirem contingências indesejáveis, e até antecipá-las, e incluem formas de ter sucesso mesmo com a sua ocorrência.
3. **Controlar:** É o ato de comparar o que realmente está a acontecer com o que foi planeado. Caso os dois não coincidam, é necessário tomar medidas para fazer ajustar as operações conforme o planeado. Fornece a conexão entre o que deveria acontecer e o que acontece. Sem controlo, não existe ligação entre planos e execução.
4. **Melhorar:** Para muitas empresas, um processo de melhoria contínua tornou-se uma norma, a fim de permanecerem competitivas. Se uma empresa melhora em todos os aspetos de gestão, melhora em cada atividade e nos atributos que lhe dão vantagem competitiva. Assim, aumenta a vantagem competitiva, a quota de mercado e o seu lucro.

2.1.3. Serviço após Venda

Atualmente, num mundo industrial competitivo, onde os produtos estão cada vez mais customizados e as margens de lucro estão a diminuir. A tendência observada é de que as empresas precisam de serviços adicionais para acrescentar valor aos seus principais produtos, a fim de torná-los mais atraentes para os clientes finais (Cavaliere *et al.*, 2009; Lagemann *et al.*, 2013).

Neste contexto, dentro da área do serviço, o serviço após venda tem vindo a adquirir um papel estratégico para o negócio de uma empresa, pois tornou-se cada vez mais importante como fonte de diferenciação e de quota de mercado (as margens de lucro são, frequentemente, mais elevadas do que as obtidas pelas vendas do produto e pode gerar, pelo menos, três vezes o volume de negócios da compra original durante um dado ciclo de vida do produto), bem como um condutor estratégico para a retenção de clientes. O serviço ao cliente envolve todas as atividades que asseguram que um produto está disponível para uso sem problemas para os consumidores ao longo da sua vida útil. Tradicionalmente, o serviço após venda encontra-se

relacionado a atividades de serviço de manutenção e reparação. No entanto, com as necessidades dos clientes, tem vindo a estender-se a outras atividades ao longo das últimas décadas (Cavalieri et al., 2009).

De acordo com alguns autores (Finch e Luebbe, 1995; Fitzsimmons e Fitzsimmons, 2001) as empresas que prestam serviços podem ser agrupadas em 4 categorias de serviços

- Serviço industrial: designadamente companhias aéreas, restaurantes de *fast food*, hotéis, entre outros;
- Serviço em massa: nomeadamente, empresas de retalho, escolas, entre outros;
- Serviço de atendimento: nomeadamente, manutenção e reparação automóvel, hospitais, clínicas dentárias, entre outros;
- Serviço profissional: nomeadamente, empresas de advocacia, entre outros.

O serviço de manutenção e reparação do setor automóvel encontra-se inserido na categoria de serviço de atendimento, estando associado a uma elevada interação com o cliente e a baixa intensidade de trabalho (Finch e Luebbe, 1995; Fitzsimmons e Fitzsimmons, 2001). Estes dois fatores proporcionam desafios para a gestão do serviço, no sentido de tornar o serviço mais eficiente, como se observa na Figura 2.1.

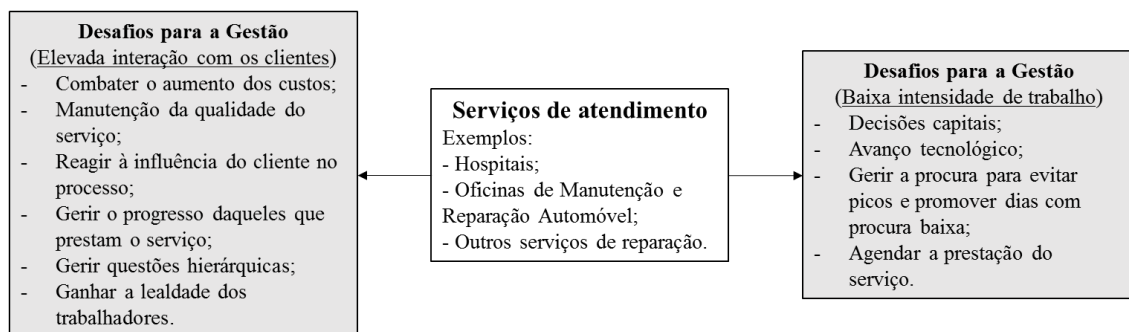


Figura 2.1 – Desafios para a gestão nos serviços de atendimento.

Adaptado de: Fitzsimmons e Fitzsimmons (2001)

A Tabela 2.1 mostra as atividades mais afetadas pela elevada interação com os clientes e de que forma é que estas atividades contribuem para as tarefas de gestão do serviço.

Tabela 2.1 – Efeitos da elevada interação com os clientes nas atividades de gestão.

Adaptado de: Finch e Luebbe (1995), p.54.

Atividades mais afetadas	Elevada interação com os clientes	Tarefas de gestão
Mapeamento de processos	O processo tem influência direta no cliente.	Organização e planeamento.
Agendamento	Agendamento diário dos trabalhadores. Clientes devem ser acomodados.	Planeamento e controlo.
Qualificação dos trabalhadores	Os trabalhadores, independentemente da sua especificação, devem saber interagir com o cliente.	Controlo e melhoria.
Gestão da qualidade	Níveis de qualidade percebidos.	Controlo e melhoria.
Tempos <i>standard</i>	O tempo do serviço depende das exigências do cliente.	Controlo e melhoria.
Pagamento de salários	A variabilidade exige sistema de salários com base no tempo.	Planeamento e controlo.
Gestão da capacidade	A capacidade deve corresponder à procura para evitar a perda de vendas.	Planeamento e controlo.
Previsão	A curto-prazo. Orientada para o tempo do serviço.	Organização e planeamento.

2.1.2.1. Medição do Desempenho Operacional

Durante a prestação de serviços, muitas são as influências e as perturbações que afetam o processo de entrega do serviço. Onde tanto a procura como a oferta de serviços industriais estão expostos a vários tipos de incerteza. Desta forma, as empresas são obrigadas a monitorizar a prestação do seu serviço relativo à eficácia e eficiência. Neste sentido, é fundamental desenvolver e implementar metodologias tais como a medição de desempenho, que é necessária para determinar potenciais melhorias para a organização de serviços com base em dados passados e atuais. Para isso, é importante definir métricas apropriadas para quantificar e ajudar a compreender o estado atual, a tomar consciência dos défices dentro da organização, a fim de deduzir medidas e, finalmente, para avaliar os efeitos das medidas que têm sido implementadas para a melhoria da organização dos serviços (Lagemann *et al.*, 2013).

Os indicadores de desempenho podem ser definidos como itens de informação recolhidos em intervalos regulares para acompanhar o desempenho de um sistema. São a base para a avaliação do desempenho das organizações e dos seus processos internos. Ajudam a controlar a prestação de serviços ao permitir a comparação dos resultados previstos e alcançados (Lagemann *et al.*, 2013).

São utilizadas diferentes abordagens para classificar os indicadores de desempenho do serviço prestado. Por exemplo, existem classificações direcionadas para (Lagemann *et al.*, 2013):

- o serviço: processo, potencial e resultado;
- o desempenho: ocupação, qualidade, custos, tempo, satisfação do cliente, flexibilidade;
- ou por tipos de entrega: por exemplo, manutenção, agendamento, reparação, logística de peças de reposição.

Subsequentemente é descrito um dos indicadores de desempenho utilizado nesta dissertação, designadamente a taxa de ocupação.

i) **Taxa de ocupação**

A ocupação corresponde ao tempo de trabalho dos recursos (incluindo a operação e o tempo de viagem) em relação ao tempo total de disponibilidade dos recursos (Lagemann *et al.*, 2013).

Este indicador de desempenho é também conhecido como a utilização, a eficiência do trabalho ou a eficiência de venda. A estatística traduz quanto do tempo disponível dos trabalhadores produtivos é realmente gasto a trabalhar de forma produtiva. O *benchmark* para este indicador é de 85% a 95%. A ocupação média das indústrias europeias corresponde a 90% (Stanković *et al.*, 2011).

A métrica do indicador de desempenho, ocupação, é a seguinte (Stanković *et al.*, 2011; Lagemann *et al.*, 2013):

$$Ocupação (\%) = \frac{Horas\ trabalhadas}{Horas\ disponíveis} \times 100 \quad (2.1)$$

2.2. Ciclo PDCA

Um dos vetores fundamentais da Gestão pela Qualidade Total (GQT) é a melhoria contínua das atividades, processos e produtos de uma organização com o objetivo de satisfazer plenamente as expectativas de todas as partes interessadas no seu desempenho. A melhoria contínua deve ser um processo sistemático que permite a concretização dos objetivos planeados de forma consistente e gradual (Pereira e Requeijo, 2012).

O ciclo PDCA (*Plan-Do-Check-Act*) proposto por W. Edwards Deming é, incontestavelmente, uma das metodologias mais conhecidas e valiosas e de fácil compreensão para a conceção da melhoria contínua (Pereira e Requeijo, 2012). O ciclo encontra-se aliado a um esforço contínuo e permanente para alcançar melhorias mensuráveis na eficiência, na eficácia, na responsabilidade, nos resultados e noutros indicadores de qualidade em serviços ou processos (Gorenflo e Moran, 2010).

A Figura 2.2 destaca a dinâmica existente entre as quatro etapas do ciclo, sendo mencionadas da seguinte maneira por alguns autores (Finch e Luebbe, 1995; Gorenflo e Moran, 2010; Pavletic *et al.*, 2010; Pereira e Requeijo, 2012):

Plan – Planear – Identificar oportunidades de melhoria, definir objetivos a atingir num determinado horizonte temporal e planear as ações que permitam atingir os objetivos;

Do – Fazer/Executar – Implementar gradualmente o plano de ação;

Check – Verificar – A partir dos dados recolhidos da etapa *Do*, monitorizar, medir e analisar os resultados da execução do plano, de modo a determinar e reportar o seu impacto;

Act – Atuar – Empreender, propor e institucionalizar métodos, ações e/ou alterações, no sentido da melhoria contínua do desempenho da organização.




Figura 2.2 – Ciclo PDCA

Fonte: Pavletic *et al.* (1995).

O aspeto mais importante no ciclo PDCA reside na etapa *Act*, que se segue à determinação do impacto do plano na organização, sendo determinante para assegurar uma atitude no sentido de melhorar continuamente o desempenho e enquadrar um novo ciclo PCDA (Pereira e Requeijo, 2012; Pavletic *et al.*, 2010).

Segundo a *American Society for Quality*, esta metodologia pode ser aplicada i) no início de um novo projeto de melhoria, ii) no desenvolvimento de um novo ou melhorado esboço de um processo, iii) num produto ou serviço, iv) na definição de um processo de trabalho repetitivo, v)

no planeamento da recolha e análise dos dados, a fim de verificar e priorizar problemas e/ou causas, vi) e na implementação de alterações numa organização.

Atualmente, o ciclo PDCA é mais do que uma ferramenta da qualidade. Representa um conceito fundamental na cultura de uma organização, no sentido da melhoria contínua dos seus processos (Pavletic *et al.*, 2010).

2.3. Modelos de Previsão

2.3.1. A Previsão como Suporte ao Planeamento

Frequentemente existe um desfasamento temporal entre a consciência de um evento iminente ou necessidade e a ocorrência desse evento. Este período de tempo, o *lead time*¹, constitui a principal razão para o planeamento e a previsão. Caso este seja zero ou muito reduzido, não há necessidade de realizar um planeamento atempado. No entanto, se o *lead time* for considerável, e o resultado do evento final estiver dependente de fatores identificáveis, o planeamento pode exercer um papel importante (Makridakis *et al.*, 1998).

Em situações administrativas e na gestão, a previsão aparece como uma ferramenta estatística, que ajuda a fornecer informação na tomada decisão sobre o planeamento da produção, do transporte e da mão-de-obra, e, no longo prazo, faculta um auxílio importante no planeamento estratégico. Por essa razão, é essencial não confundir a previsão do negócio, o planeamento e os objetivos da organização (Athanasopoulos e Hyndman, 2014):

- **Previsão:** fornece informação de eventos futuros tendo em conta os dados históricos e os fatores que afetam o negócio;
- **Objetivos:** definir o que se pretende prever e alcançar;
- **Planeamento:** determinar as ações apropriadas e necessárias com base na previsão e nos objetivos traçados.

Outro ponto importante é a distinção entre eventos externos incontrolláveis, originados pela economia nacional, pelos governos, pelos clientes e pela concorrência, e eventos internos controláveis, tais como, as decisões de marketing ou de produção numa empresa. O sucesso de uma organização depende destes dois eventos. Portanto, a previsão aplica-se a eventos externos incontrolláveis e surge como suporte de apoio e de informação, enquanto a tomada de decisão é aplicada diretamente a eventos internos controláveis. Por isso, o planeamento surge como elo de ligação dos dois eventos (Makridakis *et al.*, 1998).

¹ Conjunto dos tempos de produção e de entrega.

A previsão deve ser uma parte integrante das atividades de gestão, nomeadamente, na tomada de decisão, podendo desempenhar um papel vital em muitas áreas de uma empresa. Atualmente, as organizações necessitam de previsões a curto, médio e longo prazo, dependendo do negócio em causa (Athanasopoulos e Hyndman, 2014):

- **No curto prazo:** planeamento de produção, de recursos e de transporte. Como parte do processo de planeamento, muitas vezes, são efetuadas previsões da procura.
- **A médio prazo:** previsão de vendas para o aprovisionamento de matéria-prima, máquinas ou equipamentos, ou contratação de recursos humanos. Previsão com impacto significativo no nível de serviço e na eficiência e eficácia do processo logístico.
- **No longo prazo:** planeamento estratégico (planeamento de novos produtos, orçamentos localização, etc.). Decisões que devem ter em conta as oportunidades de mercado, os fatores ambientais e os recursos internos.

Nesse sentido, a previsão torna-se num auxílio essencial para um planeamento eficaz e eficiente (Makridakis *et al.*, 1998).

A previsão não deve ser vista como um substituto para o vaticínio, mas sim como a melhor forma de identificar e modelar padrões ou relações estabelecidas a fim de prever. Se tal atitude for aceite, os erros de previsão devem ser considerados inevitáveis e as circunstâncias que os causam investigadas (Hanke e Wichern, 2009).

Por isso, o objetivo da previsão passa por reduzir o erro de previsão para produzir previsões mais credíveis (Abraham e Ledolter, 1983). Pois, uma baixa precisão das previsões causa grandes reprogramações e custos operacionais para a atividade e pode ter impacto no desempenho logístico, tais como tempos de entrega e a qualidade (Danese e Kalchschmidt, 2011).

Nos negócios, na indústria e no governo, os formuladores das políticas devem prever o comportamento futuro de muitas variáveis críticas antes de tomar decisões. Cada situação que requer uma previsão vem com o seu próprio conjunto de problemas e as soluções para uma não são de maneira nenhuma as soluções de outra situação (Abraham e Ledolter, 1983).

2.3.2. Métodos de Previsão

A aplicação de um modelo de previsão é um procedimento quantitativo para estimar um valor futuro a partir de dados do presente e do passado. Como tal, pode ser um procedimento com base em regras algorítmicas e que não dependam de um modelo estocástico subjacente. Alternativamente, pode surgir a partir da identificação de um modelo específico para os dados, de modo a encontrar as condições ideais para realizar a previsão (Chatfield, 2001).

De acordo com vários autores (Makridakis *et al.*, 1998; Finch e Luebbe, 1995; Chatfield, 2001; Albright *et al.*, 2004; Athanasopoulos e Hyndman, 2014; Jennings *et al.*, 2015), os métodos de previsão podem ser classificados em dois grandes grupos:

➤ **Métodos Qualitativos** (ou previsão subjetiva):

Perante a falta de dados quantitativos ou a necessidade de uma previsão de longo prazo (mais de 3 anos) recorre-se a métodos que se baseiam no julgamento subjetivo, na intuição, no conhecimento do mercado e em informações adicionais relevantes.

Existem diversas abordagens qualitativas como, por exemplo, o método Delphi, as pesquisas de mercado, o júri de opinião/grupo de especialistas e a estimativa da força das vendas.

➤ **Métodos Quantitativos:**

Estes podem ser aplicados quando são satisfeitas duas condições: dados quantitativos suficientes sobre o passado e que o padrão dos dados continuará no futuro. Caso sejam satisfeitas, podem ser aplicados vários algoritmos e modelos matemáticos, sendo estes classificados em dois grupos:

- **Univariados** (modelos de séries cronológicas): constituídos por modelos de séries cronológicas, que dependem apenas das observações atuais e passadas para prever os futuros valores, ou seja, dependem apenas de uma variável explicativa, por norma, o tempo. Estes métodos podem passar pela aplicação de: médias móveis, alisamento exponencial, regressão linear e não-linear simples, decomposição clássica ou modelos ARIMA.
- **Multivariados** (modelos econométricos ou causais): utilizados quando as previsões de uma dada variável dependem de, pelo menos, uma ou mais variáveis explicativas, envolvendo mais do que uma equação, caso as variáveis sejam dependentes. Por exemplo, quando as vendas de uma empresa estão associadas ao nível de publicidade, da capacidade financeira dos clientes, das taxas de juro, entre outros. Passam pela aplicação de métodos como: a regressão múltipla, os econométricos ou as redes neuronais.

2.3.3. Processo de Implementação de Modelos de Previsão

Um processo é composto por uma série de atividades relacionadas, que transformam uma ou mais entrada(s) em uma ou mais saída(s). Todas as atividades de trabalho são realizadas em processos e a previsão não é exceção (Jennings *et al.*, 2015). De acordo com vários autores (Hanke e Wichern, 2009; Athanasopoulos e Hyndman, 2014; Jennings *et al.*, 2015), o reconhecimento de que os modelos de previsão modelam os dados gerados por eventos históricos leva à identificação de 7 atividades no processo de previsão, Figura 2.3, i) definição do problema, ii) recolha dos dados e tratamento dos dados, iii) análise dos dados, iv) seleção e ajuste do(s) modelo(s), v)

validação do(s) modelo(s), vi) previsão e vii) monitorização do desempenho do modelo de previsão.




Figura 2.3 – Processo de Implementação de modelos de previsão.

Adaptado de: Jennings *et al.* (1995) e de Hanke e Winchern (2009).

1. Definição do problema: envolve a compreensão de como a previsão será utilizada, de acordo com as expectativas estabelecidas. As questões que devem ser abordadas durante esta fase incluem i) qual a forma desejada da previsão (por exemplo: são necessárias previsões mensais?), ii) qual o horizonte de previsão, iii) qual a frequência com que as previsões devem ser revistas e iv) qual o nível necessário de precisão da previsão, a fim de se tomar boas decisões no negócio ao qual se está inserido. Esta etapa surge, também, como uma oportunidade para a tomada de decisão relativa ao uso de intervalos de previsão, como uma medida do risco associado às previsões. Muitas vezes, é necessário aprofundar muitos aspetos do sistema de negócio, exigindo a definição adequada dos componentes que podem influenciar a previsão.

2. Recolha e tratamento de dados: consiste em obter dados históricos relevantes à(s) variável(eis) que se pretende(m) prever. A chave aqui é "relevante", pois, muitas vezes, os métodos e os sistemas de recolha e armazenamento de informação mudam com o tempo e nem todos os dados históricos são úteis para o problema atual. Muitas vezes, é necessário lidar com valores em falta de algumas variáveis, potenciais *outliers* ou outros problemas com os dados que ocorreram no passado.

3. Análise de dados: é um passo preliminar importante para a seleção do modelo de previsão a ser implementado. Esta etapa passa por identificar comportamentos nos dados através de métodos estatísticos ou gráficos. Portanto, verificar se existe tendência significativa, sazonalidade ou a presença do ciclo do negócio (*ciclicidade*) na série cronológica. Este conjunto de informação irá por norma sugerir os métodos de previsão quantitativos e os modelos que se podem adequar. Posteriormente, os dados da série cronológica são divididos em dois segmentos - um para ajustamento do modelo e outro para testes de desempenho/validação do modelo. Esta divisão é realizada de modo arbitrário e denomina-se de validação cruzada.

4. Seleção e ajuste do(s) modelo(s): consiste em escolher um ou mais modelos de previsão e ajustar aos padrões identificados nos dados na etapa anterior. Por conseguinte, os parâmetros do(s) modelo(s) são estimados pela minimização do erro de previsão, normalmente, pelo método dos quadrados mínimos, minimizando a raiz do erro quadrático médio (equação 2.14).

5. Validação do(s) modelo(s): consiste numa avaliação do modelo de previsão para determinar o comportamento provável nas condições pretendidas. Etapa que serve para examinar que magnitude dos erros de previsão terá o modelo quando é utilizado para prever novos dados. Desta forma, é possível fornecer orientações úteis sobre como o modelo de previsão irá executar, quando expostos a novos dados, e pode ser uma abordagem valiosa para discriminar entre modelos de previsão concorrentes e optar pelo melhor.

6. Previsão: envolve a implementação do modelo e a geração das previsões do modelo, após o cumprimento rigoroso das etapas anteriores. É importante assegurar que a compreensão relativa ao uso do modelo e à geração de previsões rápidas através dele se torne uma rotina tanto ou quanto possível.

7. Monitorização do desempenho do modelo de previsão: deve ser uma atividade contínua após a implementação de um modelo para garantir que este, ainda, realiza previsões de forma satisfatória. Faz parte das previsões as alterações das condições ao longo do tempo e, por isso, um modelo que teve um bom desempenho no passado pode deteriorar o seu desempenho. Normalmente, a deterioração do desempenho irá resultar em maiores ou mais sistemáticos erros de previsão. Consequentemente, a monitorização dos erros de previsão é uma parte essencial de um bom processo de previsão. As cartas de controlo para erros de previsão são uma forma simples, mas eficaz, para monitorar rotineiramente o desempenho de um modelo de previsão.

2.3.4. Série Cronológica

2.3.4.1. Componentes

Uma série cronológica é constituída por dados históricos, que compõem uma sequência de observações ao longo do tempo. Por exemplo, as vendas mensais de um determinado produto, as taxas de juros semanais, os lucros anuais, as temperaturas máximas diárias e o consumo de eletricidade por hora, constituem séries cronológicas (Chatfield, 2001).

As observações de uma série estão espaçadas por intervalos de tempo fixos, ou seja, igualmente espaçados, que podem assumir um espaçamento desde horas, dias, meses, anos (Finch e Luebbe, 1995).

As características básicas dos dados, incluindo padrões e observações incomuns, podem estar associadas a fatores explicativos. Por exemplo, a competitividade industrial, muitas vezes, afeta as séries cronológicas de produção; enquanto as mudanças do governo (estratégias, orçamentos, etc.) afetam os padrões de séries económicas. Por isso, os gráficos são a forma mais eficaz de identificar o efeito de tais acontecimentos nos dados (Makridakis *et al.*, 1998).

Da leitura de uma série cronológica é possível visualizar e distinguir quatro tipos de padrões mais comuns i) aleatoriedade, ii) sazonalidade, iii) *ciclicidade* e iv) tendência. De acordo com vários autores (Finch e Luebbe, 1995; Makridakis *et al.*, 1998; Albright *et al.*, 2004) são definidos do seguinte modo:

Aleatoriedade: é a componente imprevisível e irregular, intrínseca às séries cronológicas. A aleatoriedade pode estar associada a estímulos imprevisíveis no sistema, ao comportamento imprevisível das pessoas que interagem com o sistema, entre outros.

Sazonalidade (padrão periódico): Consiste num padrão repetitivo visível nos dados, onde se observa picos ou quebras em períodos homólogos (geralmente, em dias da semana, meses, trimestres ou estações do ano), o que não significa que os valores de um período para o outro tenham de ser os mesmos. As vendas de produtos como refrigerantes e gelados, e o consumo doméstico de energia elétrica são exemplos onde está presente este tipo de padrão.

Ciclicidade: Existe quando são visualizados nos dados, períodos aleatórios de grandes aumentos ou quebras, devido a flutuações económicas (recessão ou expansão) associadas ao ciclo do negócio em causa.

A grande diferença deste padrão para o padrão sazonal reside na irregularidade dos picos. Enquanto o padrão sazonal tem um comprimento constante e se repete numa base regular e periódica, a *ciclicidade* varia no comprimento e não se repete num período fixo. Além disso, num ciclo o comprimento médio é mais longo (superior a 1 ano) e a magnitude tem maior variabilidade do que a sazonalidade (Makridakis *et al.*, 1998).

Tendência: Representa a não *estacionaridade*², em média, da série. Característica associada a um aumento ou diminuição gradual dos valores das observações, ao longo do tempo.

As observações que compõem as séries cronológicas podem, por vezes, ser afetadas por eventos incomuns, perturbações ou erros que criam efeitos adulterados na série e resultam em padrões extraordinários nas observações, ou seja, que não estão de acordo com a maioria das observações na série cronológica. Tais observações incomuns podem ser referidas como *outliers*. Estes podem ser o resultado de eventos externos incomuns, tais como greves, mudanças políticas ou económicas repentinas, mudanças bruscas de um sistema físico, e assim por diante, ou simplesmente devido ao registo ou erros grosseiros na medição (Box *et al.*, 1994).

² Processo que não varia no tempo.

2.3.4.2. Tratamento Estatístico

O tratamento de dados pode incluir a modificação de valores atípicos, identificar e corrigir erros óbvios, e preencher (ou imputar) quaisquer observações em falta. A construção de uma série cronológica para cada variável pode revelar comportamentos pouco comuns, como i) descontinuidades/valores em falta e ii) *outliers*, o que requer o seu tratamento (Chatfield, 2001).

i) Descontinuidades/valores em falta

Os métodos para a estimação dos valores em falta podem recorrer à (Gounder et al., 2015):

- Média da série: Substitui os valores em falta com o valor média da série de dados;
- Ou à média de pontos próximos (médias móveis): Substitui os valores em falta com a média dos valores mais próximos, onde o espaço de pontos próximos é o número de valores válidos acima e abaixo do valor em falta usadas para calcular a média.

ii) Detecção de *Outliers*

Um *outlier* é um ponto incomum nos dados, que ocorre dentro de um regime padrão. Um *outlier* não é uma mudança de padrão, mas apenas um valor de dados aberrante devido a um choque de uma só vez num sistema, derivado de um erro de recolha de dados ou, simplesmente, um valor extremo que ocorre por acaso (Armstrong, 2001). Um *outlier* é uma observação que se encontra a uma distância anormal de outros valores numa amostra aleatória de uma população.

De acordo com a literatura (Armstrong, 2001; Adnan *et al.*, 2004), sabe-se que os *outliers* podem ter influência profunda sobre a análise estatística e, muitas vezes, podem levar a conclusões incorretas, pois os *outliers* e outros valores extremos podem ser muito influentes na maioria dos testes paramétricos. Uma maneira simples, habitualmente, utilizada para identificar os valores aberrantes, baseia-se no conceito do método *box-plot* e envolve o uso de quartis. O método *box-plot* é um método baseado na identificação gráfica de valores extremos e que é apelativo não só na sua simplicidade, mas também porque não utiliza os potenciais valores extremos para calcular uma medida de dispersão. Os limites interiores e exteriores são definidos por quartis, e, por conseguinte, não são afetados por alguns valores extremos. Tal afetação poderia conduzir à não deteção de alguns *outliers* (Adnan *et al.*, 2004).

O procedimento utiliza a mediana e os quartis inferior e superior (definidos por percentis de 0,25 e 0,75), se o quartil mais baixo é Q_1 e no quartil superior é Q_3 , então a diferença $Q_3 - Q_1$ denomina-se por intervalo interquartil ou *IIQ*. Os limites interiores inferior e superior,

respetivamente f_1 e f_3 , e os limites exteriores inferior e superior, respetivamente F_1 e F_3 , são definidos, geralmente com base nas equações (2.2), (2.3), (2.4) e (2.5) (Adnan *et al.*, 2004):

$$f_1 = Q_1 - 1,5 \times IIQ \quad (2.2)$$

$$f_3 = Q_3 + 1,5 \times IIQ \quad (2.3)$$

$$F_1 = Q_1 - 3 \times IIQ \quad (2.4)$$

$$F_3 = Q_3 + 3 \times IIQ \quad (2.5)$$

As observações que se situam entre f_1 e F_1 ou f_3 e F_3 são considerados *outliers* “suaves”, enquanto as observações inferiores a F_1 e superiores a F_3 são considerados *outliers* extremos (Adnan *et al.*, 2004).

2.3.4.3. Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACP)

i) Função de autocorrelação (FAC)

Outra forma de identificar componentes não aleatórias (tendência, sazonalidade, entre outras), para além de gráficos, passa pelo cálculo de *autocorrelações* de uma série cronológica. Sendo uma *autocorrelação* um tipo de correlação utilizado para medir se os valores de uma série cronológica estão relacionados com os seus próprios valores passados (Albright *et al.*, 2004). Ou seja, uma correlação entre a mesma série, em que uma delas se encontra desfasada por 1, 2, ou mais períodos (Makridakis *et al.*, 1998).

A partir da série cronológica constituída por $\{Y_1, Y_2, \dots, Y_N\}$, o coeficiente de *autocorrelação* para a amostra com um desfasamento temporal de k (*lag* k) é, normalmente, calculado conforme a equação (2.6) (Chatfield, 2001).


$$c_k = \frac{\sum_{t=1}^{N-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{n} \quad (2.6)$$

Para $k = 0, 1, 2, \dots$, e o coeficiente de *autocorrelação* (r_k) na amostra *lag* k é então calculada conforme a equação (2.7).

$$r_k = \frac{c_k}{c_0} = \frac{\sum_{t=1}^{N-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^N (Y_t - \bar{Y})^2} \quad (2.7)$$

O gráfico r_k em função de k denomina-se pela função de *autocorrelação* (FAC) ou de *correlograma*. É, provavelmente, a ferramenta mais útil na análise de séries cronológicas, a seguir ao gráfico da série. Apresenta-se como uma ferramenta importante na avaliação do comportamento e das componentes de uma série cronológica (Chatfield, 2001). É, frequentemente, utilizado para verificar se está presente ou não a componente sazonalidade numa

dada série e o comprimento da sazonalidade, de modo a identificar modelos adequados às situações específicas da série e para determinar se a série de dados é estacionária (Gounder *et al.*, 2015). Por exemplo, a presença de sazonalidade anual numa determinada série de dados pode apresentar um padrão conforme a Figura 2.4 a), e a não *estacionaridade*, em média, pode apresentar um padrão conforme a Figura 2.4 b).



a) FAC evidencia sazonalidade de 12 períodos.

b) FAC evidencia não *estacionaridade* em média.

Figura 2.4 – Função de autocorrelação de uma série com sazonalidade e função de autocorrelação de uma série não estacionária, em média.

Adaptado de: Makridakis *et al.* (1998).

Normalmente, pode-se calcular *autocorrelações* para o maior número de desfasamentos. No entanto, é prática comum considerar o número de desfasamentos (k) não mais do que 25% do número de observações (n), uma vez que os primeiros desfasamentos são tipicamente o mais importante (Albright *et al.*, 2004).

ii) Função de autocorrelação parcial (FACP)

As *autocorrelações* parciais são utilizadas para determinar a ordem de um modelo de *autoregressão* ($AR(p)$) (Box *et al.*, 1994). Num modelo de *autoregressão* são usadas para medir o grau de associação entre Y_t e Y_{t-k} , quando os efeitos dos *lags* 1, 2, 3, ..., $k-1$ são removidos (Makridakis *et al.*, 1998).

A função de *autocorrelação* parcial (FACP), ϕ_{kj} , onde o coeficiente j numa representação *autoregressiva* é de ordem k , de modo que ϕ_{kk} seja o último coeficiente. Esta função é descrita equação (2.8) (Box *et al.*, 1994).

$$r_j = \phi_{k1}r_{j-1} + \dots + \phi_{k(k-1)}r_{j-k+1} + \phi_{kk}r_{j-k} \quad j = 1, 2, \dots, k \quad (2.8)$$

Os coeficientes ϕ_{kj} satisfazem um conjunto de equações que levam às equações de *Yule-Walker* e que podem ser determinados para $k = 1, 2, 3, \dots$, sucessivamente, da seguinte forma (Box *et al.*, 1994):

$$\phi_{11} = r_1, \quad \phi_{22} = \frac{\begin{vmatrix} 1 & r_1 \\ r_1 & 1 \end{vmatrix}}{\begin{vmatrix} 1 & r_1 \\ r_1 & 1 \end{vmatrix}} \quad \phi_{33} = \frac{\begin{vmatrix} 1 & r_1 & r_2 \\ r_1 & 1 & r_2 \\ r_2 & r_1 & 1 \end{vmatrix}}{\begin{vmatrix} 1 & r_1 & r_2 \\ r_1 & 1 & r_2 \\ r_2 & r_1 & 1 \end{vmatrix}} \dots \phi_{kk}$$

iii) Teste estatístico para FAC e FACP

Teoricamente, todos os coeficientes de *autocorrelação*, para uma série de números aleatórios devem ser zero. Mas no caso de amostras finitas, cada uma das *autocorrelações* da amostra não será exatamente zero (Makridakis *et al.*, 1998). De acordo com vários estudos (Bartlett (1946), Quenouille (1949), e outros), foi demonstrado que os coeficientes de autocorrelação (r_k) e de autocorrelação parcial (ϕ_{kj}) de dados com ruído branco³ seguem uma distribuição que pode ser aproximada a uma curva normal de $\mu = 0$ e $\sigma = \frac{1}{\sqrt{n}}$, em que n é o número de dados da amostra (Box *et al.*, 1994).

Esta informação pode ser usada para desenvolver um teste de hipóteses em relação ao coeficiente de *autocorrelação* da população, ρ , que testa duas hipóteses a i) hipótese nula, $H_0: \rho = 0$ ou a ii) hipótese alternativa, $H_1: \rho \neq 0$. Por norma, recorre-se ao teste *t-student* ou de normalidade, de modo a determinar se os coeficientes de *autocorrelação* são significativamente diferentes de 0. A equação (2.9) mostra a estatística de teste (Makridakis *et al.*, 1998; Hanke e Wichern, 2009).

$$t_{calculado} = \frac{r_k - \rho}{\sigma_{r_k}} = \frac{r_k - 0}{1/\sqrt{n}} \quad (2.9)$$

Para $n - 1$ graus de liberdade e com um determinado nível de significância, α , se a hipótese nula for rejeitada, pode-se concluir que existe efetivamente uma *autocorrelação* significativa no *lag* k .

Em suma, a distribuição *amostral* e o desvio padrão permitem interpretar os resultados da análise de *autocorrelação* para que se possa distinguir o que é o padrão do que é ruído branco nos dados (Makridakis *et al.*, 1998).

2.3.4.4. Coeficiente de Correlação

O coeficiente de correlação é uma medida padrão da associação ou mútua dependência entre duas variáveis (X e Y), normalmente, designada por r_{XY} . Os seus valores variam entre -1 e +1, indicando uma forte relação negativa, uma fraca relação (se for aproximadamente 0) ou uma

³ Quando não há um padrão absoluto na série de dados (Makridakis *et al.*, 1998).

forte associação positiva (Makridakis *et al.*, 1998). O coeficiente de correlação é dado pela equação (2.10) (Makridakis *et al.*, 1998; Albright *et al.*, 2004):

$$r_{XY} = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})/(n-1)}{s_X s_Y} = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum(X_i - \bar{X})^2} \sqrt{\sum(Y_i - \bar{Y})^2}} \quad (2.10)$$

Onde $s_X = \sqrt{\frac{\sum(X_i - \bar{X})^2}{n-1}}$ é o desvio padrão da amostra X e $s_Y = \sqrt{\frac{\sum(Y_i - \bar{Y})^2}{n-1}}$ é o desvio padrão da amostra Y . O termo n é o número de observações e i a observação no período i .

Geralmente, aceita-se que a significância estatística do coeficiente de correlação está relacionada com o tamanho da amostra. O tamanho da amostra e o coeficiente de correlação da população, ρ , são os fatores mais importantes que influenciam a magnitude do coeficiente de correlação (Gurbuz *et al.*, 2007).

Para comprovar se o coeficiente de correlação é significativo, deve-se realizar o seguinte teste de hipóteses em relação ao coeficiente de correlação da população, ρ , com base no coeficiente de correlação da amostra, r_{XY} (Gurbuz *et al.*, 2007):

$$H_0: \rho = 0$$

$$H_1: \rho \neq 0$$

A estatística de teste t é:

$$t_{calculado} = \frac{r_{XY} \sqrt{n-2}}{\sqrt{1 - r_{xy}^2}}$$

Com $n - 2$ graus de liberdade na tabela t -Student. Caso o valor de $t_{calculado}$ seja superior ao valor crítico de $t, t_{n-2; \alpha}$, deve-se rejeitar a hipótese nula. Se a hipótese nula, com um determinado nível de significância, α , for rejeitada, pode-se concluir que existe efetivamente uma relação significativa entre as variáveis X e Y .

Esta inferência estatística é importante numa análise preliminar dos modelos multivariados, nomeadamente, no modelo de regressão linear múltipla, para determinar a influência de certos fatores/variáveis na série cronológica (Makidrakis *et al.*, 1998).

2.3.5. Precisão da Previsão

2.3.5.1. Medidas Estatísticas *Standard*

A medição da precisão é fundamental para verificar se um modelo se ajusta aos dados da série cronológica fornecida (Albright *et al.*, 2004) e, posteriormente, para avaliar a qualidade de previsão. Por isso, recorre-se às medidas do erro de previsão, que são essenciais para avaliar a qualidade dos modelos de previsão e para comparação entre modelos de previsão, de modo a optar pelo melhor (Brebels *et al.*, 2013).

Um modelo de previsão está sempre sujeito ao erro, erro esse que pode ser quantificado em cada período. Assim, o erro de previsão (resíduo) para cada período t é definido pela diferença entre o valor previsto (P_t) e o real (V_t), equação (2.11) (Abraham e Ledolter, 1983).

$$e_t = P_t - V_t \quad (2.11)$$

Se e_t for negativo, significará que se está a prever um valor inferior ao realmente obtido. No caso de e_t ser positivo, significará que se está a prever um valor superior ao realmente obtido.

Para se averiguar quanto à qualidade do ajustamento ou da previsão devem ser medidas duas componentes no erro de previsão. A primeira componente do erro é relativo à sua inclinação ou o seu enviesamento, ou seja, se a tendência para a previsão é ser, em média, por excesso ou por defeito. Uma previsão que não esteja enviesada, ao nível do erro terá tanto por excesso como por defeito, sendo assim, a soma dos erros será aproximadamente igual a zero (Finch e Luebbe, 1995).

O erro médio (EM), equação (2.12) surge como abordagem mais comum para medir o enviesamento (Finch e Luebbe, 1995).

$$EM = \frac{1}{n} \sum_{t=1}^n e_t \quad (2.12)$$

Onde n é o número de observações a considerar.

A segunda componente do erro de previsão é a sua magnitude, que é medida através do erro absoluto médio (EAM), equação (2.13), que dá, em termos absolutos, o desvio médio da previsão em relação ao valor real (Finch e Luebbe, 1995).

$$EAM = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (2.13)$$

Ou, recorrendo à raiz do erro quadrático médio (REQM) conforme a equação (2.14) (Albright *et al.*, 2004):

$$REQM = \sqrt{\frac{1}{n} \sum_{t=1}^n (e_t)^2} \quad (2.14)$$

Porém, quando o desempenho dos modelos de previsão precisa de ser comparado entre diferentes séries cronológicas, medidas de precisão que dependem da escala, como o EAM e a REQM, são inadequadas, uma vez que séries com valores muito elevados podem dominar as comparações. Nestas circunstâncias, as medidas *adimensionais* têm de ser empregues, sendo o erro percentual absoluto médio (EPAM) a medida mais utilizada (Goodwin e Lawton, 1999). O erro percentual para cada período t (ep_t) e o EPAM durante n períodos são definidas, respetivamente pela equação (2.15) e (2.16).

$$ep_t = \frac{P_t - V_t}{V_t} \times 100 \quad (2.15)$$

$$EPAM = \frac{1}{n} \sum_{t=1}^n |ep_t| \quad (2.16)$$

2.3.5.2. Comparação e Critério de Seleção dos Modelos

Regularmente, há vários modelos concorrentes que são utilizados para prever uma série cronológica particular. Consequentemente, a seleção de um modelo de previsão adequado torna-se de considerável importância prática.

A decisão de utilizar um modelo de previsão particular é baseada, em parte, na determinação do modelo que produz erros de previsão menores (Hanke e Wichern, 2009) quando comparado aos restantes modelos. Portanto, o critério mais importante para a escolha de um modelo de previsão é a sua precisão, ou quão perto a previsão prediz o evento real (Abraham e Ledolter, 1983).

O critério que se baseia na minimização da REQM é utilizado, frequentemente, uma vez que leva a soluções matemáticas mais simples (Abraham e Ledolter, 1983).

Outro critério de decisão é a estatística R^2 , denominada por coeficiente de determinação, estimada com base na equação (2.17) (Jennings *et al.*, 2015).

$$R^2 = 1 - \frac{\sum_{t=1}^n (e_t)^2}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (2.17)$$

O denominador da equação é apenas a soma total dos quadrados das dispersões dos valores reais em relação à média, que é constante (não dependendo do modelo, mas da série de dados). O numerador é a soma do erro quadrático (EQ).

Portanto, a seleção do modelo que maximiza R^2 é equivalente a selecionar o modelo que minimiza a raiz do erro quadrático médio – REQM – (equação, 2.14). Valores elevados de R^2 sugerem um bom ajuste aos dados históricos, uma vez que a soma do erro quadrático diminui, consideravelmente, quando os parâmetros são adicionados a um modelo (Jennings *et al.*, 2015).

Um modelo de previsão que apresente um valor da estatística R^2 inferior a 0,4 ($R^2 < 0,4$), indica uma capacidade preditiva baixa, enquanto por outro lado um valor da estatística R^2 superior a 0,6 ($R^2 \geq 0,6$), aponta para uma boa capacidade preditiva e, finalmente, um valor da estatística R^2 entre 0,4, inclusive, e 0,6 ($0,4 \leq R^2 < 0,6$), representa uma capacidade preditiva média. Esta medição é subjetiva, uma vez que nem sempre um modelo de previsão bem ajustado à série de dados implica uma previsão satisfatória (Pellegrini, 2000).

Portanto, ao selecionar o modelo que proporciona o melhor ajuste aos dados históricos, geralmente, não significa que assegure as melhores previsões dos novos dados (Makridakis *et al.*, 1998).

2.3.5.3. Intervalo de Previsão

Por norma, é desejável proporcionar não apenas valores previsão, mas a incerteza associada aos valores, geralmente, sob a forma de intervalos de predição. É útil, uma vez que fornece a informação da previsão com a "pior" ou "melhor" caso estimado e o quão fiável a previsão pode ser. Os intervalos de previsão são, geralmente, baseados na REQM, que é uma estimativa do desvio padrão do erro de previsão. O pressuposto para a construção do intervalo é de que os erros de previsão são normalmente distribuídos com média de zero. Partindo deste pressuposto, um intervalo de previsão para a próxima observação é definido, aproximadamente, pela equação (2.18) (Makridakis *et al.*, 1998).

$$Y_{t+1} \pm z_{\alpha} REQM \quad (2.18)$$

2.3.6. Modelos de Previsão Quantitativos

2.3.6.1. Alisamento Exponencial Simples

O alisamento exponencial simples (AES) fornece uma média móvel exponencialmente ponderada de todos os valores anteriormente observados. O modelo é, muitas vezes, apropriado para séries de dados sem tendência e sem sazonalidade. O objetivo é estimar o nível atual, sendo esta estimativa utilizada como previsão de valores futuros. Portanto, o alisamento exponencial

simples confere, continuamente, uma estimativa à luz das experiências mais recente (Hanke e Wichern, 2009).

Este método baseia-se no alisamento de valores passados de uma série, de um modo exponencial decrescente. A observação mais recente (Y_t) recebe o maior peso da constante de alisamento, α (onde $0 < \alpha < 1$), a próxima observação mais recente (Y_{t-1}) recebe menos peso, $\alpha(1 - \alpha)$ e a observação de dois períodos anteriores recebe ainda menos peso (Y_{t-2}), $\alpha(1 - \alpha)^2$ e, assim por diante (Hanke e Wichern, 2009).

No alisamento exponencial simples, a nova previsão (\hat{Y}_{t+1}) pode ser vista como uma soma ponderada da observação atual (Y_t) e a previsão atual (\hat{Y}_t). O peso da constante α ($0 < \alpha < 1$) é associado à observação atual e o peso $1 - \alpha$ é associado à previsão atual. Assim, apresenta-se a equação do alisamento exponencial simples na equação (2.19) (Albright *et al.*, 2004; Hanke e Wichern, 2009).

$$\hat{Y}_{t+1} = \alpha Y_t + (1 - \alpha) \hat{Y}_t = \hat{Y}_t + \alpha(Y_t - \hat{Y}_t) = \hat{Y}_t + \alpha e_t \quad (2.19)$$

Onde e_t é o erro de previsão no período t .

Quando α está próximo do valor de 1, \hat{Y}_{t+1} será essencialmente a observação atual, Y_t (equivalentemente, \hat{Y}_{t+1} será \hat{Y}_t mais o ajuste substancial para qualquer erro que ocorreu na previsão anterior, e_t). Reciprocamente, quando α está próximo do valor de 0, \hat{Y}_{t+1} será muito semelhante à previsão atual, \hat{Y}_t , e a observação atual, Y_t , terá um impacto reduzido.

O valor ótimo para α é obtido pela minimização da estatística REQM (Albright *et al.*, 2004).

É possível mostrar que as previsões obtidas a partir de alguns modelos de alisamento exponencial são idênticas com as previsões de determinados modelos ARIMA. Por exemplo, o modelo de AES (equação, 2.19) é equivalente ao modelo ARIMA(0,1,1) (Makridakis *et al.*, 1998).

2.3.6.2. Holt-Winters

Se a série de dados está exposta a uma tendência linear, o modelo de *Holt*⁴ é apropriado. No entanto, se a série de dados apresenta, também, sazonalidade, o modelo de *Holt*, por conta própria, não consegue lidar com o problema (Makridakis *et al.*, 1998). Nesse sentido, *Winters* em 1960 apresentou uma extensão ao modelo de *Holt* para modelar a sazonalidade, o modelo de *Holt-*

⁴ É uma extensão do alisamento exponencial simples que modela a tendência dos dados, através de duas constantes, uma para o nível e outra para a tendência (Armstrong, 2001).

Winters. O modelo de *Holt-Winters* é baseado em três constantes de alisamento - uma para o nível, uma para tendência e uma para a sazonalidade (Armstrong, 2001).

O modelo de *Holt-Winters* pode ser modelado de acordo com uma sazonalidade aditiva ou multiplicativa (Makridakis *et al.*, 1998).

No caso de a série conter sazonalidade multiplicativa, as quatro equações utilizadas por este modelo são, respetivamente as equações (2.20), (2.21), (2.22) e (2.23) (Hanke e Wichern, 2009):

$$1. \text{ Estimativa do nível: } L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (2.20)$$

$$2. \text{ Estimativa da tendência: } T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (2.21)$$

$$3. \text{ Estimativa da sazonalidade: } S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (2.22)$$

$$4. \text{ Previsão: } P_{t+p} = (L_t + pT_t)S_{t-s+p} \quad (2.23)$$

Onde L_t é o novo valor de alisamento ou do nível estimado da série para o período t ; α é a constante de alisamento para o nível; Y_t é o valor atual no período t ; β é a constante de alisamento para a estimativa da tendência; T_t é a estimativa da tendência no período t ; γ é a constante de alisamento para estimar a sazonalidade; S_t é o valor sazonal no período t ; p é o futuro período para o qual se pretende prever; s é o comprimento da sazonalidade; P_{t+p} é o valor previsto para o período $t + p$.

Tal como acontece com todos os métodos de alisamento exponencial, são precisos valores iniciais das componentes (L_t , T_t , S_t) para iniciar o algoritmo. Existem várias abordagens, mas visto que se pretende determinar estimativas iniciais dos índices sazonais, pode-se usar os dados de, pelo menos, uma temporada completa (ou seja, períodos s). Desta forma, o nível é inicializado, assumindo a média de s (comprimento da sazonalidade) valores, como mostra a equação (2.24) (Makridakis *et al.*, 1998).

$$L_s = \frac{1}{s}(Y_1 + Y_2 + \dots + Y_s) \quad (2.24)$$

Para inicializar a tendência, é conveniente usar dois períodos sazonais, equação (2.25).

$$T_s = \frac{1}{s} \left[\frac{Y_{s+1} - Y_1}{s} + \frac{Y_{s+2} - Y_2}{s} + \dots + \frac{Y_{s+s} - Y_s}{s} \right] \quad (2.25)$$

Finalmente, os índices sazonais são inicializados utilizando o rácio entre os primeiros valores de dados para a média do primeiro período sazonal, de modo que:

$$S_1 = \frac{Y_1}{L_s}, S_2 = \frac{Y_2}{L_s}, \dots, S_s = \frac{Y_s}{L_s}$$

Por outro lado, se a componente sazonal for aditiva, embora seja pouco comum. As equações básicas para o modelo aditivo de *Holt-Winters* aditivo são, respetivamente as equações (2.26), (2.27), (2.28) e (2.29) (Makridakis *et al.*, 1998).

$$1. \text{ Estimativa do nível: } L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (2.26)$$

$$2. \text{ Estimativa da tendência: } T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (2.27)$$

$$3. \text{ Estimativa da sazonalidade: } S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (2.28)$$

$$4. \text{ Previsão: } P_{t+p} = L_t + pT_t + S_{t-s+p} \quad (2.29)$$

Os valores iniciais para L_s e T_s são idênticos aos do modelo multiplicativo. No entanto, para inicializar os índices sazonais recorre-se à diferença:

$$S_1 = Y_1 - L_s, S_2 = Y_2 - L_s, \dots, S_s = Y_s - L_s$$

As constantes α , β e γ são seleccionadas pela minimização da REQM (equação, 2.14). A abordagem mais comum para a determinação destes valores é a utilização de um algoritmo de otimização para encontrar as constantes de ponderação ótimas (Hanke e Wichern, 2009).

2.3.6.3. ARIMA

Os modelos *autoregressivos* integrados de médias móveis (ARIMA) são uma classe de modelos capazes de representar séries cronológicas estacionárias, bem como não estacionárias. Não envolvem variáveis independentes na sua construção. Em vez disso, recorrem a informações da própria série para gerar previsões e dependem, fortemente, de padrões de *autocorrelação* nos dados (Hanke e Wichern, 2009).

Portanto, a metodologia para a identificação, montagem e verificação de modelos ARIMA apropriados foi fortemente avançado pelo trabalho de dois especialistas em estatística, G. E. P. Box e G. M. Jenkins (1970). Por esta razão, a modelação e previsão é, muitas vezes, referida como a metodologia de *Box-Jenkins* (Hanke e Wichern, 2009).

A base da abordagem *Box-Jenkins* à modelação de séries cronológicas consiste em três fases, i) de identificação de potenciais modelos através da FAC e da FACP, ii) de estimação e teste aos parâmetros do(s) modelo(s), e seleção do melhor, e iii) de aplicação do modelo de previsão. Na fase de estimação, os parâmetros dos modelos ARIMA são estimados pela minimização do REQM (equação, 2.14) associado ao ajuste do modelo (Makridakis *et al.*, 1998).

Para simplificação dos modelos ARIMA, é utilizado um dispositivo de notação muito útil nas equações destes modelos, o operador de atraso, B, que é utilizado como se segue (Makridakis *et al.*, 1998):

$$BY_t = Y_{t-1}$$

Noutras palavras, B , opera sob Y_t , tendo o efeito de atrasar os dados um período. Duas aplicações de B para Y_t atrasa os dados dois períodos, como se segue:

$$B(BY_t) = B^2Y_t = Y_{t-2}$$

O operador de atraso é conveniente para descrever o processo de diferenciação, no caso de uma série estacionária. Uma primeira diferença pode ser escrita como:

$$Y'_t = Y_t - Y_{t-1} = Y_t - BY_t = (1 - B)Y_t$$

Por norma, uma diferença de ordem d pode ser expressa da seguinte maneira:

$$(1 - B)^d Y_t$$

Esta notação é conveniente, pois os termos podem ser multiplicados, ser visto o efeito derivado da sua combinação e reduz a complexidade da equação.

2.3.6.3.1. Modelos para séries estacionárias

i) Modelos $AR(p)$

Uma série cronológica Y_t é caracterizada por ser um processo autorregressivo de ordem p ($AR(p)$) quando a soma linear ponderada dos últimos p valores somada a um choque aleatório para que (Box *et al.*, 1994; Makridakis *et al.*, 1998; Chatfield, 2001; Hanks e Wichern, 2009):

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t$$

Onde Y_t é a variável resposta (dependente) no período t ; $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ é a variável resposta desfasada nos períodos $t - 1, t - 2, \dots, t - p$, desempenhando o papel de variáveis independentes; $\phi_1, \phi_2, \dots, \phi_p$ são os coeficientes autorregressivos a serem estimados; ϕ_0 é o coeficiente relacionado com a média do processo, μ , da seguinte forma: $\phi_0 = \mu(1 - \phi_1 - \phi_2 - \dots - \phi_p)$; e_t o erro no período t , o que representa os efeitos de variáveis não explicadas pelo modelo.

Para o processo AR estacionário de ordem elevada, a FAC será, tipicamente uma mistura, ou termos que diminuem exponencialmente ou onda sinusoidal amortecida. Uma propriedade útil de um processo de $AR(p)$ é que este mostra que a $FACP$ é nula para desfasamentos superiores a p . O que significa que a amostra $FACP$ pode ser utilizada para ajudar a determinar a ordem de um processo de *autoregressão* (Chatfield, 2001).

ii) Modelos MA(q)

Uma série cronológica Y_t é caracterizada por ser um processo de média móvel de ordem q (MA(q)) quando a soma linear ponderada dos últimos q choques aleatórios para que (Box *et al.*, 1994; Makridakis *et al.*, 1998; Chatfield, 2001; Hanks e Wichern, 2009):

$$Y_t = \mu + e_t - \omega_1 e_{t-1} - \omega_2 e_{t-2} - \dots - \omega_q e_{t-q}$$

Onde Y_t é a variável resposta (dependente) no período t ; μ é a constante que representa a média do processo; $\omega_1, \omega_2, \dots, \omega_q$ são os coeficientes de *autocorrelação* estimados; e_t é o erro no instante t , o que representa o efeito das variáveis não explicadas pelo modelo; $e_{t-1}, e_{t-2}, \dots, e_{t-q}$ são os erros nos períodos anteriores ao período t e que são incorporados na resposta Y_t .

iii) Modelos ARMA(p, q)

Os elementos dos modelos autorregressivos e médias móveis, ARMA(p, q), podem ser combinados de forma a produzir uma grande variedade de modelos, tendo em conta seguinte a equação (Box *et al.*, 1994; Makridakis *et al.*, 1998; Chatfield, 2001; Hanks e Wichern, 2009):

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t - \omega_1 e_{t-1} - \omega_2 e_{t-2} - \dots - \omega_q e_{t-q}$$

Ou, utilizando o operador atraso,

$$(1 - \phi_1 B - \dots - \phi_p B^p) Y_t = \phi_0 + (1 - \omega_1 B - \dots - \omega_q B^q) e_t$$

Ou, ainda,

$$\phi_p(B) Y_t = \phi_0 + w_q(B) e_t$$

Onde $\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ é um polinómio autorregressivo de ordem p e $w_q(B) = 1 - \omega_1 B - \dots - \omega_q B^q$ é um polinómio médias móveis de ordem q , e e_t é um resíduo no período t .

Os modelos ARMA(p, q) podem descrever uma enorme variedade de comportamentos nas séries estacionárias e muitas séries reais podem ser modeladas de uma forma mais parcimoniosa, isto é, com menos parâmetros, através de um modelo ARMA, do que por um processo AR ou MA puro.

A Tabela 2.2 mostra os comportamentos teóricos possíveis das *autocorrelações* e *autocorrelações* parciais para um modelo AR(p), MA(q) ou ARMA(p, q).

Tabela 2.2 - Descrição do padrão teórico apresentado nas funções de autocorrelação e de autocorrelação parciais para um modelo $AR(p)$, $MA(q)$ e $ARMA(p,q)$.

Adaptado de: Hanke e Wichern (2009).

Modelo	FAC	FACP
AR(p)	Decaimento exponencial ou sinusoidal amortecida	Quebra acentuada para zero a partir do lag $p + 1$
MA(q)	Quebra acentuada para zero a partir do lag $p + 1$	Decaimento exponencial ou sinusoidal amortecida
ARMA(p, q)	Decaimento exponencial ou sinusoidal amortecida	Decaimento exponencial ou sinusoidal amortecida

2.3.6.3.2. Modelos para séries não estacionárias

i) Modelo ARIMA (p, d, q)

Na prática, muitas séries cronológicas são não estacionárias e, por isso, não se pode aplicar processos estacionários AR, MA ou ARMA diretamente. Uma maneira possível de lidar com séries não estacionárias passa por aplicar diferenças, de modo a torná-las estacionárias. As primeiras diferenças, ou seja, $(Y_t - Y_{t-1}) = (1 - B)Y_t$, podendo ser diferenciadas para dar segundas diferenças, e assim por diante. As d diferenças podem ser escrita da seguinte forma $(1 - B)^d Y_t$ (Chatfield, 2001). Por isso, se a série é não estacionária $d > 0$ recorrendo-se a um processo ARIMA (p, d, q), onde a letra "I" no acrônimo significa integrada e d denota o número de diferenças realizadas. (Box *et al.*, 1994; Makridakis *et al.*, 1998; Chatfield, 2001; Hanks, 2009) A equação do modelo ARIMA (p, d, q) é apresentada na equação (2.30).

$$(1 - \phi_1 B - \dots - \phi_p B^p)(1 - B)^d Y_t = (1 - w_1 B - \dots - w_q B^q) e_t \quad (2.30)$$

Ou,

$$\phi_p(B)(1 - B)^d Y_t = w_q(B) e_t$$

Onde $\phi_1, \phi_2, \dots, \phi_p$ são os parâmetros autorregressivos e $\omega_1, \omega_2, \dots, \omega_q$ os parâmetros médias móveis.

As formas mais simples e frequentes do modelo ARIMA são ARIMA (0,1,0), ARIMA (1,1,0), ARIMA (0,1,1), e ARIMA (1,1,1).

ii) Modelo SARIMA $(p, d, q)(P, D, Q)_s$

Nas séries que apresentam sazonalidade, com s períodos de tempo por ano, então um modelo sazonal ARIMA (SARIMA) pode ser obtido pela generalização da equação (2.30). Introduzindo o operador B^s que é demonstrado da seguinte forma $B^s Y_t = Y_{t-s}$. Assim, a diferenciação sazonal pode ser escrita como $(Y_t - Y_{t-1}) = (1 - B^s)Y_t$. Portanto, um termo autorregressivo sazonal é aquele em que Y_t depende linearmente de Y_{t-s} (Chatfield, 2001). Um modelo SARIMA é composto por termos não-sazonais de ordem (p, d, q) e por termos sazonais de ordem (P, D, Q) , sendo abreviado por modelo SARIMA $(p, d, q)(P, D, Q)_s$ e a sua equação encontra-se definida equação (2.31) (Box *et al.*, 1994; Makridakis *et al.*, 1998; Chatfield, 2001; Hanks e Wichern, 2009).

$$\begin{aligned} (1 - \phi_1 B - \dots - \phi_p B^p)(1 - \phi_1 B^s - \dots - \phi_p B^{s \times P})(1 - B)^d(1 - B^s)^D Y_t \\ = (1 - w_1 B - \dots - w_q B^q)(1 - \theta_1 B^s - \dots - \theta_P B^{s \times P})e_t \end{aligned} \quad (2.31)$$

Ou, de uma forma mais simplificada:

$$\phi_p(B)\Phi_P(B^s)(1 - B)^d(1 - B^s)^D Y_t = w_q(B)\theta_P(B^s)e_t$$

Na maioria das aplicações práticas, os valores de p, q, P e Q são quase sempre inferiores ou iguais a 2, enquanto os valores de d e D , habitualmente, assumem os valores inteiros 0 ou 1. As FAC e FACP dos modelos SARIMA apresentam um decaimento exponencial ou sinusoidal amortecido sobre *lags* não sazonais e sazonais, respetivamente.

2.3.6.3.3. Verificação do modelo

Uma verificação da adequação do modelo é fornecido por um teste qui-quadrado com base na estatística de Ljung-Box Q. Este teste examina os tamanhos das *autocorrelações* residuais (dos erros) como um grupo. A estatística de teste Q é expressa pela equação (Hanke e Wichern, 2009).

$$Q = n(n+2) \sum_{k=1}^m \frac{r_k^2(e)}{n-k}$$

Que segue, aproximadamente, uma distribuição do *qui-quadrado* com $m - r$ (número de *autocorrelações* menos o número de parâmetros estimados no modelo ARIMA) graus de liberdade. Onde $r_k(e)$ é a *autocorrelação* residual no lag k ; n é o número residual; k é período do lag; m é o número de *lags* a ser testados.

Se o *p-value* associado à estatística Q é menor que 0,05 (Tabela I.1 do Anexo I), o modelo é considerado inadequado. Por isso, deve-se considerar um modelo novo ou modificado e prosseguir a análise até o modelo satisfatório ser determinado.

2.3.6.3.4. Critério de seleção dos modelos ARIMA

Tem sido desenvolvida uma abordagem para a seleção de modelos ARIMA que considera tanto o ajuste do modelo e o número de parâmetros. O critério de informação de Akaike (1974), ou AIC, seleciona o melhor modelo, a partir de um grupo de modelos concorrentes, com base no valor mínimo estimado pela equação de AIC, equação (2.32) (Hanke e Wichern, 2009).

$$AIC = \ln \sigma^2 + \frac{2}{n}r \quad (2.32)$$

Onde \ln é logaritmo de base e ; σ^2 é a fração da soma dos quadrados dos erros por n ; n é o número de observações (erros/resíduos); e r é número total de parâmetros (incluindo a constante) num modelo ARIMA.

2.3.6.4. Regressão Linear Múltipla

Num modelo de regressão linear simples, a variável dependente pode ser representada por Y é influenciada apenas por uma variável independente, X . Porém, num modelo de regressão linear múltipla, existe mais do que uma variável independente. Assim, a variável dependente, Y , passa a ser influenciada pelas variáveis independentes, X_1, X_2, \dots, X_k , em que k é número de variáveis independentes. No modelo de regressão múltipla, a resposta média \bar{Y}_t (seja t o período) é assumida como sendo uma função linear das variáveis independentes, $X_{1,t}, X_{2,t}, \dots, X_{3,t}$ (Hanke e Wichern, 2009).

A equação do modelo para estimar um valor para um determinado período t , \hat{Y}_t , é expressa na equação (2.33) (Makridakis et al., 1998; Hanke e Wichern, 2009).

$$\hat{Y}_t + e_t = \beta_0 + \beta_1 X_{1,t} + \beta_2 X_{2,t} + \dots + \beta_k X_{k,t} + e_t = Y_t \quad (2.33)$$

Onde $Y_t, X_{1,t}, X_{2,t}, \dots, X_{3,t}$ cada uma das variáveis, Y_t (dependente), $X_{1,t}, X_{2,t}, \dots, X_{3,t}$ (independentes), respetivamente, apresentam o valor real para o período. \hat{Y}_t é o valor estimado da regressão para o período t . $\beta_0, \beta_1, \beta_2, \dots, \beta_k$ são os coeficientes de regressão e e_t é o resíduo do período t definido pela equação (2.34).

$$e_t = Y_t - \hat{Y}_t \quad (2.34)$$

2.3.6.4.1. Variáveis explicativas relacionadas com o tempo

a) Tempo

Quando se pretende incluir uma tendência linear no modelo de regressão, pode-se criar uma variável explicativa X_t que assume valores iguais aos tempos de observação, t (Makridakis et al., 1998)

b) Variáveis *dummy*

Às vezes, é necessário determinar como uma variável dependente está relacionada com uma variável independente quando um fator qualitativo está a influenciar a situação. Esta relação é conseguida criando uma variável *dummy*, que compreende os valores 0 e 1 (Hanke e Wichern, 2009). Esta variável pode ser aplicada no modelo de regressão linear múltipla com o objetivo de modelar i) a sazonalidade, ii) o efeito das épocas festivas, iii) entre outros (Makridakis *et al.*, 1998).

- Variável *dummy* sazonal:

Por exemplo, para modelar a sazonalidade anual passa por atribuir 1 ao mês onde está presente a componente sazonal e 0 se não estiver (Makridakis *et al.*, 1998):

$D_1 = 1$ se for o mês de janeiro e 0 se não for;

$D_2 = 1$ se for o mês de fevereiro e 0 se não for;

\vdots

$D_{11} = 1$ se for o mês de novembro e 0 se não for.

- Variável *dummy* para o efeito das épocas festivas:

Por exemplo, o efeito da época festiva natalícia na série de dados das vendas mensais pode ser modelado da seguinte maneira (Makridakis *et al.*, 1998):

$D = 1$ se for o mês de dezembro e 0 se não for.

2.3.6.4.2. Análise da variabilidade

Para inferir quanto à variabilidade do modelo de regressão linear múltipla implementado, recorre-se a uma tabela de análise de variância, a Tabela ANOVA (Tabela 2.3). Esta tem por base a decomposição da variação total de Y (SQT, soma quadrática total) na variação explicada pela regressão (SQR, soma quadrática da regressão) e na variação não explicada (SQE, soma quadrática dos erros) (Makridakis *et al.*, 1998; Hanke e Wichern, 2009):

$$\sum (Y_t - \bar{Y}_t)^2 = \sum (\hat{Y}_t - \bar{Y}_t)^2 + \sum (Y_t - \hat{Y}_t)^2$$

$$SQT = SQR + SQE$$

$$gl^5: n - 1 = k + n - k - 1$$

O desvio padrão do erro é dado por:

⁵ Graus de liberdade

$$s_{y.x's} = \sqrt{\frac{SQE}{n - k - 1}} = \sqrt{MQE}$$

Na regressão linear simples, há apenas uma variável de previsão. Por conseguinte, para testar a significância da regressão utilizando o rácio F da Tabela ANOVA é equivalente ao teste t -Student ou de Normalidade bilateral para testar se o declive da linha de regressão é zero. Para a regressão linear múltipla, o teste t -Student ou de Normalidade apenas testa a significância de uma variável independente na função de regressão, enquanto o teste F examina a significância do conjunto das variáveis independentes.

No modelo de regressão múltipla, para averiguar quanto à significância da regressão são formuladas as seguintes hipóteses:

$$H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$$

$$H_1: \text{pelo menos um } \beta_i \neq 0$$

E são testadas pelo rácio F :

$$F = \frac{MQR}{MQE}$$

Com $gl = k, n - k - 1$. Com um nível de significância α , a região de rejeição é para $F > F_\alpha$ onde F_α é o ponto superior com percentagem α , que segue uma distribuição *Fisher* com $\delta_1 = k$, $\delta_2 = n - k - 1$ graus de liberdade.

Tabela 2.3 – Tabela de análise da variância (ANOVA).

Adaptado de: Makridakis *et al.* (1998).

	gl	Soma quadrática (SQ)	Média dos quadrados (MQ)	Rácio F	F de significância
Regressão	k	SQR	$MQR = \frac{SQR}{k}$	$F = \frac{MSR}{MSE}$	F_α
Erro	$n - k - 1$	SQE	$MQE = \frac{SQE}{n - k - 1}$	-	-
Total	$n - 1$	SQT	-	-	-

Para averiguar quanto à significância de cada um dos coeficientes de regressão são formuladas as seguintes hipóteses:

$$H_0: \beta_k = 0$$

$$H_1: \beta_k \neq 0$$

E são testadas através do rácio t (equação 2.35) em relação a um valor crítico, $t_{n-k-1;\alpha}$ ou z_α , ou através do p -value. Se o p -value for menor que 0,05 (Tabela I.1 do Anexo I) pode-se afirmar que o coeficiente de regressão, β_k , é significativamente diferente de 0 e que a variável explicativa que lhe está associada é significativa na presença das restantes variáveis explicativas.

$$t = \frac{\beta_k}{\sigma_{\beta_k}} \quad (2.35)$$

De modo a quantificar a variabilidade associada à variável dependente, Y , que é explicada pela regressão, calcula-se o coeficiente de determinação, R^2 , de acordo com a equação (2.36) (Hanke e Wichern, 2009).

$$R^2 = \frac{SQR}{SQT} = \frac{\sum(\hat{Y} - \bar{Y})^2}{\sum(Y - \bar{Y})^2} = 1 - \frac{SQE}{SQT} = 1 - \frac{\sum(Y - \hat{Y})^2}{\sum(Y - \bar{Y})^2} \quad (2.36)$$

Capítulo 3 - Contextualização do Caso de Estudo

Este Capítulo pretende enquadrar o caso de estudo na empresa onde este é desenvolvido e descrevê-lo de forma objetiva, abordando a sua importância para a empresa e contextualizando o problema através da metodologia de melhoria contínua, o ciclo PDCA, nomeadamente no que diz respeito:

- à definição do plano para a recolha de dados (secção 3.2.1) – etapa *Planear*;
- aos dados recolhidos (secção 3.2.2) – etapa *Executar*;
- e à análise e avaliação do desempenho atual da oficina Soauto Expo (secção 3.2.3) – etapa *Verificar*.

3.1. Caracterização da Empresa

A empresa onde é desenvolvido o caso de estudo é a SIVA – Sociedade de Importação de Veículos Automóveis, SA. O caso de estudo é desenvolvido no âmbito da gestão da capacidade do serviço de assistência técnica de um dos concessionários Soauto da SIVA.

Nesse sentido, foi recolhida informação nas páginas oficiais na Internet, em junho de 2016, das duas empresas que integram o Grupo SAG – Soluções Automóvel Globais –, e que operam no setor de atividade automóvel, de modo a enquadrá-las quanto às áreas de negócio.

3.1.1. Grupo SAG – Soluções Automóvel Globais

O Grupo SAG – Soluções Automóveis Globais, SGPS, SA é uma *holding* com sede em Portugal que desenvolve a sua atividade no setor automóvel. A Grupo dedica-se, principalmente, à importação, distribuição, venda e aluguer de automóveis novos de passageiros e veículos comerciais, bem como de peças e acessórios das marcas que representa. A ação do Grupo SAG desenvolve-se também na venda e aluguer de carros usados.

Paralelamente, o Grupo SAG tem também desenvolvido a sua atividade em áreas complementares no setor automóvel, em particular nos segmentos da prestação de serviços após venda, serviços de financiamento de automóveis e corretagem de seguros.

O Grupo SAG opera em Portugal e no Brasil. O portefólio do Grupo inclui várias marcas automóveis: Volkswagen, Volkswagen Veículos Comerciais, Audi, Skoda, Bentley e Lamborghini.

A *holding* integra uma série de empresas, como a SIVA SA, Soauto Comércio de Automóveis SA, Rolporto SA, Rolvia SA, e a LGA, entre outros. Na Figura 3.1 encontram-se representadas as áreas de negócio do Grupo SAG.



Figura 3.1 – Áreas de negócio do Grupo SAG – Soluções Automóvel Globais.

Fonte: SIVA (2016).

3.1.2. SIVA – Sociedade de Importação de Veículos Automóveis, SA

A SIVA – Sociedade de Importação de Veículos Automóveis, SA – integra o conjunto de empresas que constituem o Grupo SAG, para a distribuição das marcas do Grupo Volkswagen no mercado português: Volkswagen, Audi, Bentley, Lamborghini, Škoda e Volkswagen Veículos Comerciais.

Foi constituída em Agosto de 1987 a partir da aquisição, pelo empresário João Pereira Coutinho, da Volkswagen Portugal Automóveis Lda., à época importador das marcas Volkswagen e Audi.

No primeiro ano de atividade, que coincidiu com a liberalização das importações de veículos provenientes da União Europeia, a SIVA vendeu mais de 16 000 veículos, quando no ano anterior as Marcas por ela representadas tinham vendido menos de 600 veículos. Em poucos anos, a SIVA relançou de forma assinalável a imagem e a credibilidade das marcas Volkswagen e Audi, em estreita parceria com o Grupo Volkswagen e as Redes de Concessionários, garantindo-lhes o lugar de destaque compatível com a qualidade e prestígio dos seus produtos.

A representação de marcas de referência alargou-se à Škoda em 1992 e às marcas de luxo Bentley e Lamborghini em 2000 e 2002, respetivamente.

Assumindo a liderança do mercado de veículos de passageiros em Janeiro de 1998, a SIVA constituiu a génese do inovador projeto integrado e multimarca que, a partir de 2000, recebeu a denominação de SAG – Soluções Automóvel Globais, SGPS SA.

Às áreas da importação e distribuição de veículos, peças e acessórios foi-se juntando uma oferta global e completa de serviços conexos com o automóvel, uma estratégia que permitiu responder com sucesso às crescentes exigências e sofisticação do mercado, assegurando uma maior satisfação e fidelização dos clientes e reforçando a parceria com o Grupo Volkswagen e Redes de Concessionários.

A capacidade de antecipar métodos e oportunidades e a aposta na inovação e nos recursos humanos foram, desde o início, os valores centrais de uma organização que elegeu como missão atingir a excelência na valorização das marcas representadas, na otimização dos recursos e na qualidade dos serviços prestados ao cliente e, como consequência, na rentabilidade da operação global.

O reconhecimento da qualidade dos produtos, do empenho e competência da equipa SIVA e seus parceiros e das estratégias seguidas, tem-se traduzido nomeadamente numa liderança sustentada do mercado automóvel em Portugal, na atribuição por duas vezes (1995 e 2009) do prémio de importador do ano Volkswagen pela Volkswagen AG e do prémio de melhor empresa de distribuição automóvel em dois anos consecutivos (2009 e 2010) pela revista Exame.

Definindo-se como Organização motivada, confiante, com sustentabilidade, virada para a satisfação de clientes com as marcas mais atrativas e os produtos mais fascinantes do mercado, a SIVA elegeu como vetores estratégicos o valor das marcas que representa, a procura de novas abordagens ao cliente numa perspetiva de interação e multicanal, a sustentabilidade dos parceiros concessionários, uma gestão cada vez mais eficiente e a inovação.

Baseada ainda nos vetores operacionais foco, dedicação e coragem, pretende a SIVA exceder sempre as expectativas dos seus parceiros e clientes.

3.1.3. Concessionários Soauto

No início de 2009, o Grupo SAG tomou a decisão de integrar as diferentes empresas do retalho (com 100% capital SAG e pertencentes à área metropolitana de Lisboa) numa única empresa denominada SOAUTO, mantendo os diferentes estabelecimentos existentes, nomeadamente: Soauto Laranjeiras, Soauto Expo, Soauto Carnaxide, Expocar Cascais e Soauto Barreiro. Esta integração teve como objetivo reduzir custos e burocracias inerentes à existência de diferentes empresas, facilitando o alinhamento das respetivas políticas e procedimentos.

Os concessionários Soauto dedicam-se ao comércio de veículos automóveis, novos e usados, e das respetivas peças e acessórios, bem como à prestação do serviço de assistência técnica destinado à manutenção e reparação de veículos automóveis e à prestação de serviços conexos nas oficinas autorizadas pela marca.

3.1.3.1. Processos Base do Serviço de Assistência Técnica

A prestação do serviço de assistência técnica estende-se desde que o cliente entra em contacto, por telefone ou outro meio (e-mail, visita, outros), com a oficina autorizada pela marca para agendar a manutenção e reparação do seu veículo até ao momento em que o cliente é inquirido sobre a sua satisfação em relação ao serviço que lhe foi prestado.

A prestação do serviço das oficinas autorizadas pela marca pode ser dividida e sequenciada em 7 processos, conforme a Figura 3.2. São denominados pela marca por processos base do serviço, onde se reúne os procedimentos de trabalho recorrentes e necessários. Através dos processos base do serviço, as oficinas autorizadas pela marca procuram dar prioridade máxima à qualidade e integridade de todos os procedimentos e etapas do trabalho a realizar, cada vez que recebem um contacto de um cliente e lhe prestam um serviço, de modo a assegurar a qualidade do mesmo.

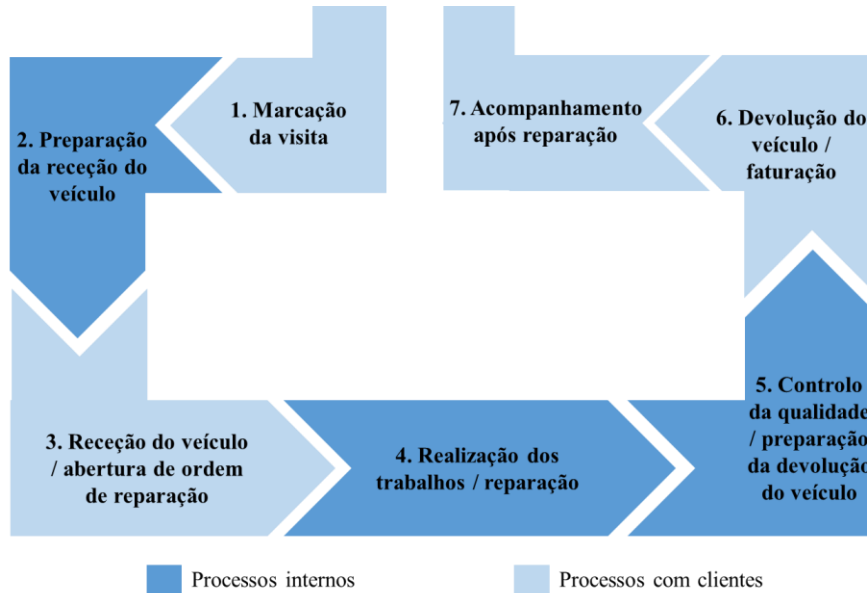


Figura 3.2 – Processos base do serviço de manutenção e reparação.

Fonte: SIVA (2016). *Programa autodidata de operações de serviço*.

Os processos base do serviço desenvolvem-se em sete etapas bem definidas, nomeadamente:

Etapla 1. Marcação da visita: Envolve o procedimento de marcação da visita do cliente à oficina autorizada, em que a central de marcações ouve cuidadosamente e regista os dados do cliente, os dados do veículo, as necessidades e os problemas do cliente e tudo aquilo que ficar acordado (data e hora da visita e orçamento);

Etapla 2. Preparação da receção do veículo: Preparação para a chegada do cliente (cliente regular ou novo, necessidades, etc.) e do respetivo veículo (historial de reparações, ações de campo, etc.). Envolve, ainda, a preparação da ordem de reparação, as medidas a tomar e a sua capacidade de resposta de uma forma completa (peças de substituição, ferramentas, mão-de-obra necessária, veículo de substituição, entre outros);

Etapla 3. Receção do veículo / abertura da ordem de reparação: Processo de inspeção do veículo de uma forma sistemática e completa e registo de todos os pedidos do cliente, danos no veículo e todos os aspetos acordados (data de entrega do veículo, etc.). Os colaboradores do concessionário envolvido na reparação são informados do que foi inspecionado, registado e acordado;

Etapla 4. Realização dos trabalhos / reparação: Preenchimento da ordem de reparação de uma forma exata e completa, incluindo os trabalhos adicionais; identificação dos problemas e processamento das ordens de reparação, de acordo com o tempo previsto; registo do tempo de mão-de-obra para cada operação na ordem de reparação; e, em caso de necessidade, proceder à extensão da ordem de reparação (verificar a disponibilidade das peças de substituição, verificar capacidade oficial, confirmar a mobilidade do cliente, calcular custos adicionais, entre outros);

Etapla 5. Controlo da qualidade / preparação da devolução do veículo: Processos de verificação e respetiva documentação da qualidade do trabalho realizado e de preparação do veículo para a devolução ao cliente;

Etapla 6. Devolução do veículo / faturação: Processo onde são explicados o trabalho realizado e a fatura ao cliente, assegurando depois a entrega do veículo;

Etapla 7. Acompanhamento após reparação: Após a visita do cliente à oficina, é determinada e avaliada a sua satisfação e tiradas conclusões quanto a medidas corretivas a adotar.

A avaliação correta de uma ordem de reparação é muito importante para a satisfação do cliente. No primeiro contacto com o cliente é efetuada uma classificação dos tipos de ordem de reparação i) pequena (K), ii) standard (S) e iii) diagnóstico (D). Esta classificação é efetuada segundo os critérios do grupo Volkswagen (Figura 3.3), de modo a facilitar a organização das ordens de reparação quando efetuadas as marcações com os clientes.




Figura 3.3 – Fase de classificação dos tipos de ordem de reparação.

Fonte: SIVA (2016).

Na Tabela 3.1. são apresentados os critérios para a classificação dos diferentes tipos de ordens de reparação.

Uma ordem de reparação é classificada de pequena (K) quando se trata de uma ordem com trabalhos claramente especificados, nomeadamente, substituição de escovas do limpa-para-brisas, de pneus ou de lâmpadas. Uma ordem de reparação é classificada de *standard* (S) quando se trata de uma ordem padrão, nomeadamente, de inspeção ou de reparação do sistema de travagem ou de embraiagem. Uma ordem de reparação é classificada de Diagnóstico (D) quando se trata de uma ordem com trabalho especializado, como por exemplo, verificar a causa do acendimento da luz de sobreaquecimento, ruídos ou avarias no sistema de navegação.

As ordens de reparação da categoria K (pequenas) podem ser resolvidas de uma forma mais simples nos processos base do serviço. Os riscos associados à necessidade de repetição da reparação são relativamente reduzidos nesta categoria. Os clientes recebem um serviço rápido e sem complicações, pelo que o índice de satisfação do cliente no *Customer Satisfaction Survey* (CSS) a este nível é elevado. O CSS é um programa informático que avalia a satisfação do cliente após a visita à oficina.

Na categoria S (ordem de reparação *standard*) e, em particular, na categoria D (ordem de reparação de diagnóstico), o risco de reparações repetidas aumenta, devido ao facto da complexidade das ordens de reparação aumentar. Portanto, nestas categorias os concessionários focam-se fundamentalmente na qualidade, recorrendo a técnicos mais experientes e qualificados, para que o índice de satisfação do cliente no CSS continue elevado.

Tabela 3.1 – Tipos de ordem de reparação.

Fonte: SIVA (2016).

Ordens de Reparação		
Pequena (K)	Standard (S)	Diagnóstico (D)
São ordens que englobam substituição de escovas do limpador-para-brisas, substituição de pneus, substituição de lâmpadas.	São ordens associadas a inspeções, reparações do sistema de travagem ou de embraiagem.	Por exemplo, verificar a causa do acendimento da luz de sobreaquecimento, ruídos, avarias no sistema de navegação.
<ul style="list-style-type: none"> - Ordem de reparação com trabalhos claramente especificados; - Não é necessário teste de estrada; - Veículo aceite sem marcação prévia; - Sem trabalho de diagnóstico; - Possibilidade de planeamento prévio de peças de substituição; - Inquérito de satisfação; - Sem necessidade de trabalho especializado; - Ofertas de pacotes de serviço; - Facilidade em marcar data da visita; - Não é necessária receção direta. 	<ul style="list-style-type: none"> - Leque de reparações limitado; - Possibilidade de teste de estrada com o cliente; - Informação ao cliente sobre o tempo necessário para a receção do veículo; - Necessidade de receção do veículo por parte de um colaborador especializado (<i>check-list</i> de verificação); - Possibilidade de planeamento prévio de peças de substituição (nalguns casos); - Inquérito de satisfação; - Necessidade de prazo ajustável (folga de tempo); - Consulta de ações de campo; - Importante consultar o historial de reparações. 	<ul style="list-style-type: none"> - Leque de reparações não é limitado; - Maior necessidade de trabalhos de diagnóstico (viagem de experiência, receção direta, etc.); - Receção do veículo fora das horas de maior afluência; - Gestão da visita e receção do veículo por parte de um colaborador qualificado; - Maior dificuldade na obtenção de peças de substituição; - Inquérito de satisfação; - Necessidade de equipamento de diagnóstico; - Necessidade de trabalho especializado; - Importante consultar o historial de reparações; - Necessidade de prazo ajustável (folga de tempos); - Soluções de problemas técnicos (TPI's); - Necessidade de notificação DISS; - Necessidade de mobilidade alternativa dependente do tempo de reparação; - Divisão de tarefas; - Necessidade de serviço ao cliente com maior cuidado; - Possível apenas com marcação de visita com o gestor de clientes (operações); - Utilização de TPI's de serviço.

3.1.3.2. Importância do Agendamento para o Serviço de Assistência Técnica

A organização do processo produtivo da oficina inicia com o estabelecimento da data de visita do cliente e termina com a entrega do veículo reparado ao cliente. Por isso, é necessário ter em conta o tempo total de estadia do veículo, desde que o cliente o deixa até ao momento que o recolhe.

O tempo de estadia do veículo depende da intensidade dos danos, sendo influenciado por vários fatores que provocam períodos de paragem que podem ser mais ou menos longas, tais como (Jornal de Oficinas, 2012):

- A gestão de *stock* das peças de substituição;
- A capacidade de produção;
- A planificação da oficina;
- A priorização do cliente;
- E, os imponderáveis: baixas laborais, falhas no fornecimento de peças de substituição, avarias nos equipamentos, entre outros.

Por isso, a necessidade de melhorar a eficácia de agendamento dos trabalhos diários da oficina vem no sentido de conduzir ao aumento da rentabilidade e da satisfação do cliente como também da agilização dos recursos humanos e materiais.

A eficácia do agendamento permite:

- Aumentar o rigor no planeamento da necessidade de recursos, da capacidade e, correspondente, disponibilidade para satisfazer a procura;
- Assegurar o planeamento da chegada de peças no momento certo e nas quantidades certas para as intervenções de reparação, manutenção e substituição;
- Assegurar a utilização do equipamento e das instalações;
- Programar (calendarizar, escalonar) as atividades de reparação/manutenção para que os técnicos operem corretamente.

A melhoria da eficácia de agendamento tem, ainda, como objetivo de aumentar a ocupação dos seus técnicos. Com este objetivo pretende-se, por um lado, que não haja excesso de mão-de-obra para o volume de trabalhos previstos, uma vez que acarreta custos para a empresa, ou haja escassa mão-de-obra para o volume de trabalhos, o que pode implicar a perda de horas faturadas, isto é, clientes que procuram o serviço de assistência técnica e são rejeitados por falta de técnicos no serviço.

3.2. Descrição do Caso de Estudo

O caso de estudo da presente dissertação prende-se com a gestão da capacidade do serviço de assistência técnica para um dos concessionários da SIVA, a Soauto Expo. Pretende-se nesta dissertação analisar e melhorar a agenda oficial do concessionário, no que diz respeito ao agendamento dos trabalhos diários da oficina relativo às operações de mecatrónica (reparação mecânica e/ou eletrónica) a realizar na sua oficina autorizada, com base no ciclo PDCA.

O agendamento para a realização dos trabalhos na oficina corresponde a 5 principais grupos de intervenção:

- chapa (CH);
- pintura (PI);
- mecânica (M);
- eletrónica (E);
- controlo da qualidade (CQ).

No entanto, o estudo apenas incidiu nas operações de mecânica (M) e de eletrónica (E), por serem as operações que proporcionam um fluxo de trabalho contínuo na oficina e por terem, consideravelmente, um maior volume de trabalho, necessitando de designar mais técnicos para as intervenções. É um estudo agregado, ou seja, as operações de mecânica e de eletrónica são analisadas em conjunto (operação de mecatrónica), devido ao facto da interdependência entre as duas operações, pois um técnico pode estar qualificado para executar as duas operações ou pode-se formar uma equipa multifacetada para uma intervenção em simultâneo num determinado veículo.

3.2.1. Agenda Oficial

A agenda oficial é um conjunto de procedimentos desenvolvido recentemente pela SIVA, aplicada às suas oficinas autorizadas, para que seja possível:

- definir fases de agendamento e certos “estados” na oficina / tipos de horas trabalhadas pelos técnicos;
- e recolher dados, de forma a avaliar o desempenho da oficina.

Estes procedimentos interligam o processo de marcação de uma ordem de reparação (processo-base 1) e o processo de realização dos trabalhos de reparação (processo-base 4).

As marcações dos trabalhos na oficina são definidas pela central de marcações juntamente com a oficina. A central de marcações tem a responsabilidade de obter informação junto do gestor após venda do concessionário, relativamente à perspetiva geral da disponibilidade da oficina, antes de sugerir uma hora para a visita do cliente ao concessionário. A marcação apenas tem em conta os períodos de disponibilidade em que todo o trabalho possa ser feito. O agendamento/marcação é efetuado por tempos médios de reparação.

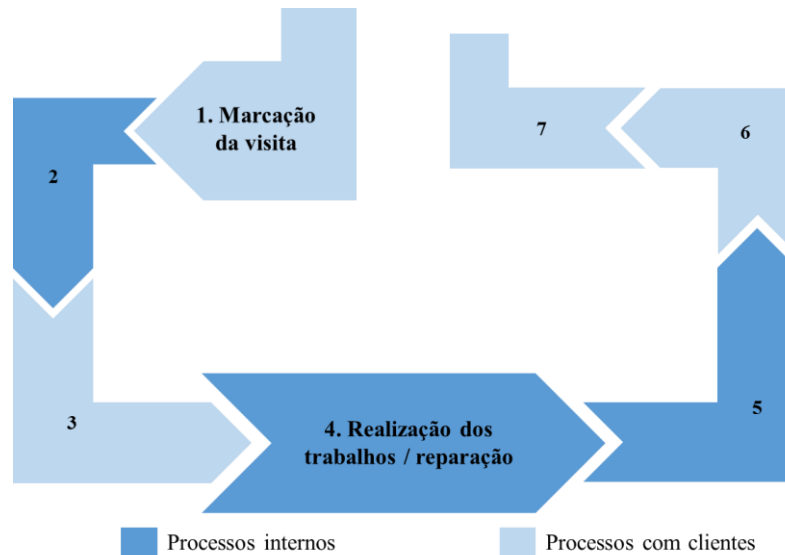


Figura 3.4 – Processos base do serviço de manutenção e reparação envolvidos na agenda oficial.

Fonte: SIVA (2016).

O prazo de marcações para um determinado dia não se encontra padronizado, ou seja, as marcações podem ser realizadas até à véspera do determinado dia, pois o objetivo do serviço de assistência técnica do concessionário (oficina) reside na faturação. Portanto, não existe um tempo *standard* para definir um agendamento atempado, também pelo facto das necessidades para cada ordem de reparação serem diferentes.

O agendamento dos trabalhos envolve duas fases, a primeira fase relativa à definição de objetivos e a segunda etapa relativa às marcações e planeamento de recursos. Após as marcações efetuadas para o dia em causa, segue-se a terceira fase, a realização dos trabalhos na oficina para o determinado dia, onde é possível distinguir quatro “estados” na oficina / horas trabalhadas pelos técnicos. Nas secções seguintes são explicadas estas três fases.

3.2.1.1. Primeira Fase do Agendamento – Definição de Objetivos

As marcações são executadas de uma forma não normalizada, às quais a central de marcações tem a preocupação de não preencher a totalidade da capacidade oficial quando agenda horas para clientes com marcação, de modo a deixar algum espaço de reserva (folga) para i) extensões de ordens de reparação, ii) para clientes sem marcação e iii) emergências.

Assim, a capacidade diária da oficina é definida pela central de marcações em termos de horas disponíveis na agenda, isto é, as horas-homem (H.h) que estão ainda disponíveis e que podem ser preenchidas com trabalho. No máximo, as horas disponíveis para as operações de mecânica correspondem a 120 H.h por dia, o que equivale a 16 técnicos (cada um num turno de 7,5 horas).

No entanto, a disponibilidade da agenda está sujeita a alterações (nomeadamente, à redução das H.h) devido a faltas dos técnicos, greves, formações, períodos de férias, entre outros.

Tendo em conta o número de técnicos disponíveis para um determinado dia da semana, a central de marcações, juntamente com o gestor após venda do concessionário, definem o objetivo de horas a trabalhar, que corresponde, por norma, a 95% das horas disponíveis na agenda. A partir deste objetivo é definido o número de horas a agendar que, por norma corresponde a 75% do número de horas a trabalhar. Posteriormente, o número de horas de trabalho extraordinário é estabelecido de acordo com o número de horas a trabalhar e o número de horas previstas relativas a faltas dos clientes com marcação permitindo, assim, dar também resposta a imprevistos e assegurar uma taxa de ocupação elevada dos técnicos da oficina.

É importante definir-se o número de horas de trabalho extraordinário, pois permite designar o número de técnicos responsáveis pelas ordens de reparação destinadas a clientes que não efetuaram marcação prévia e ter uma perspetiva de disponibilidade (capacidade) para ordens de reparação sem agendamento prévio.

A Figura 3.5 esquematiza a primeira fase do agendamento – a definição de objetivos –, ou seja, o modo como é definido o número de horas a trabalhar, o número de horas a agendar e o número de horas de trabalho extra num dia de 120 H.h.

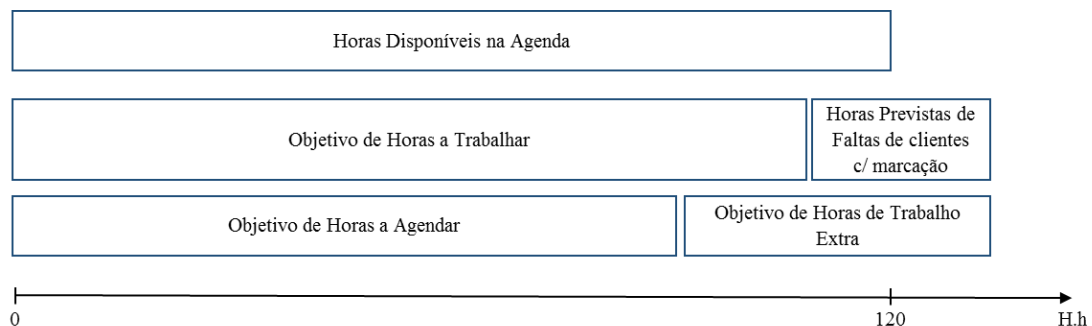


Figura 3.5 – 1ª Fase do agendamento – Definição dos objetivos.

3.2.1.2. Segunda Fase do agendamento – Marcações e Planeamento dos Recursos

De acordo com o objetivo de horas a agendar, a central de marcações procura marcar na agenda, até ao dia definido, com pedidos de clientes para reparação/manutenção dos veículos e com ordens de reparação pendentes na oficina, de modo a atingir o objetivo.

O prazo de marcações para um determinado dia não se encontra padronizado, ou seja, as marcações são realizadas até à véspera do dia definido.

Contudo, o objetivo de horas a agendar nem sempre é conseguido, pois a preocupação da central de marcações é que haja trabalho marcado para todos os dias da semana, sem que se verifique uma grande disparidade na taxa de ocupação dos técnicos.

Por exemplo, em dois dias consecutivos que estejam definidas 120 H.h disponíveis na agenda e não seja possível atingir o objetivo definido para cada um dos dias, a central de marcações procura equilibrar o trabalho marcado nos dois dias para que não haja um dia de muita ocupação e no outro dia uma baixa ocupação dos técnicos da oficina.

Logo, de acordo com a atividade de marcações dos trabalhos, até ao determinado dia, é obtida uma programação dos trabalhos do dia, Figura 3.6.




Figura 3.6 – 2ª Fase do agendamento – Marcações e planeamento dos recursos.

Desta forma, as informações relativas ao trabalho agendado – descrição do veículo e da situação, atividades a realizar, quem desempenha cada função na oficina, orçamentos, entre outros – são registadas no *software* de gestão, o denominado por Sistema de Planeamento de Marcações (TPS), que serve para apoiar o trabalho de preparação para i) a realização das atividades de serviço nas oficinas e ii) a encomenda de peças.

A partir da informação registada inicia-se o processo de preparação da receção dos veículos na receção da oficina ao nível das medidas a tomar e a sua capacidade de resposta (peças de substituição, ferramentas, técnicos necessários para o trabalho marcado, viatura de substituição, entre outros).

A Figura 3.7 realça os dois processos base do serviço de manutenção e reparação intrínsecos à segunda fase do agendamento i) as marcações e ii) a preparação da receção dos veículos.

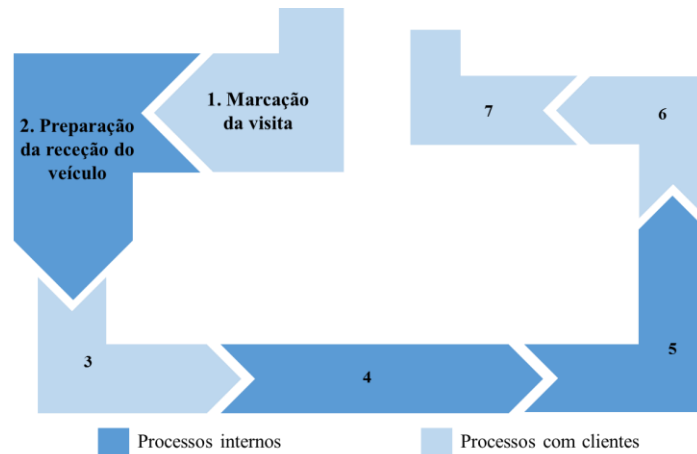


Figura 3.7 – Processos base do serviço de manutenção e reparação na definição e preparação das operações diárias na oficina.

Fonte: SIVA (2016).

A preparação dos trabalhos resulta de um fluxo de informação e de um feedback constante entre a central de marcações e o gestor de clientes da oficina (o rececionista), tendo em conta as necessidades da oficina e as existências de peças em armazém.

A Figura 3.8 apresenta os fluxos gerados na definição e preparação dos trabalhos.

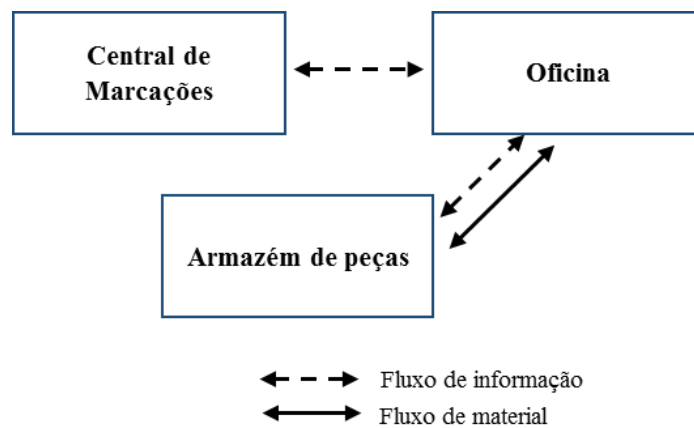


Figura 3.8 – Fluxos gerados na definição e preparação das operações diárias na oficina.

Fonte: SIVA (2016).

3.2.1.3. Realização dos Trabalhos de Manutenção e Reparação

Os trabalhos realizados diariamente no serviço de assistência técnica da oficina autorizada correspondem a trabalho associado a clientes com marcação para o dia (Agendadas M), a ordens de reparação pendentes (Agendadas O ou Extra O) e a clientes sem marcação (Extra M).

Tendo em conta esta classificação, é feita a distinção de 4 tipos de horas trabalhadas (HT) pelos técnicos, identificados na Figura 3.9. Sendo estes, o número de horas trabalhadas nos veículos:

- que foram agendados pela central de marcações relativas a i) clientes com marcação (Agendadas M) e a ii) ordens pendentes (Agendadas O);
- e que não foram agendados pela central de marcações relativas a iii) clientes sem marcação (Extra M) e a iv) ordens pendentes (Extra O).

Verifica-se, frequentemente, que o planeado nem sempre é o realizado.

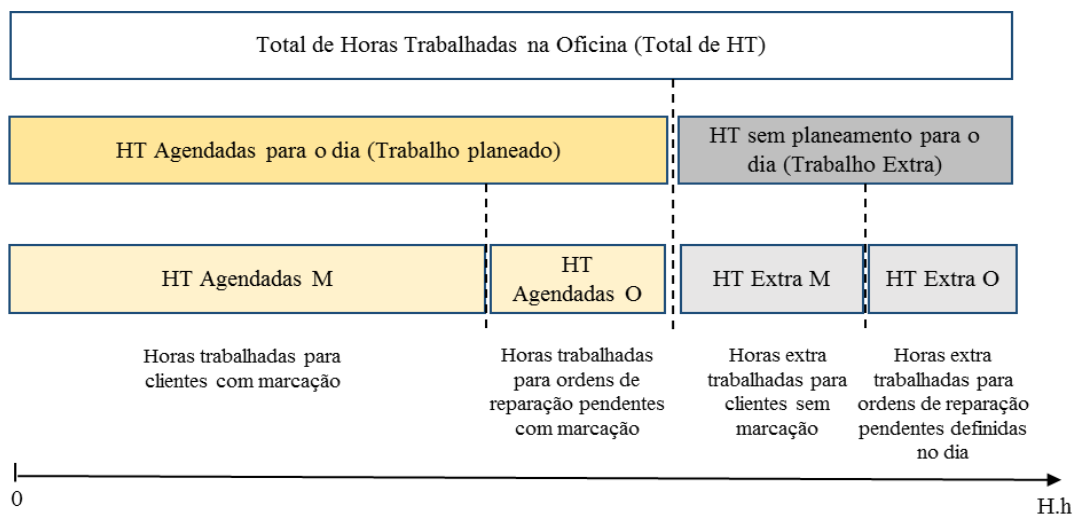


Figura 3.9 – Esquema da segmentação das horas trabalhadas pelos técnicos por tipos de utilização (“estado”).

3.2.1.4. Agendamento versus Realização

Com a aplicação da metodologia da agenda oficial, é apresentado na Figura 3.10, o esquema das fases necessárias para definir os trabalhos da oficina e os “estados” que resultam de um dia de trabalho.

A fase 1 destina-se à definição de objetivos que se estabelecem a partir da designação das horas que estão disponíveis na agenda para o dia.

A fase 2 destina-se à atividade das marcações de ordens de reparação (horas agendadas), juntamente com a atividade de planeamento, por forma a ter todos os recursos disponíveis para cada ordem de reparação marcada, assegurando a chegada de peças no momento certo e nas quantidades certas, bem como a utilização do equipamento, das instalações e dos técnicos de acordo com o volume de trabalho.

No dia em causa, com o agendamento definido para as operações de mecânica e com a execução dos trabalhos, distinguem-se 4 “estados” na oficina / tipos de horas trabalhadas pelos técnicos: horas trabalhadas para i) clientes com marcação (Agendadas M), ii) ordens de reparação pendentes marcadas (Agendadas O), iii) clientes sem marcação (Extra M) e iv) ordens de reparação pendentes definidas apenas no dia (Extra O).

É importante, ainda, ter noção que uma pequena parte das horas disponíveis reais está associada à ocorrência de tempos mortos devido à espera de material, pausas excessivas entre tarefas, entre outros.

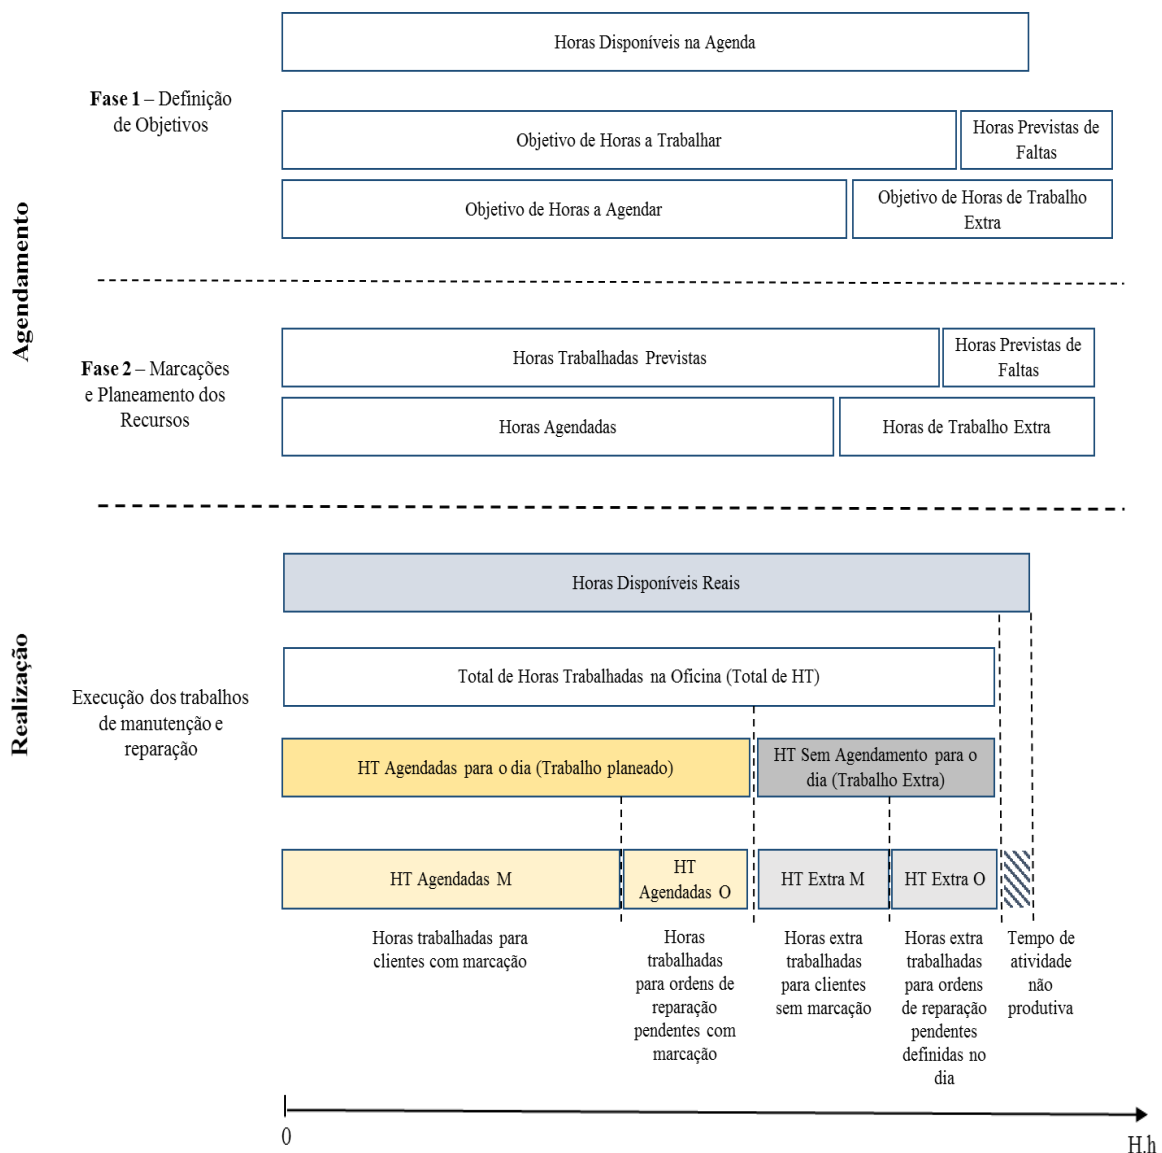


Figura 3.10 – Representação esquemática da metodologia da agenda oficial.

Fonte: SIVA (2016).

3.2.2. Fonte de Dados e Descrição das Variáveis

A análise empírica do presente estudo teve por base os dados diários fornecidos pela SIVA através do conjunto de procedimentos da agenda oficial, referente aos anos de 2014, 2015 e 2016. Os dados foram acedidos através do *software* de gestão do concessionário Soauto Expo, Sistema de Gestão do Concessionário (DMS). São 13 as variáveis extraídas da base de dados da oficina Soauto Expo. Na Tabela 3.2 cada variável é identificada por uma designação e é identificada a unidade de medida.

Tabela 3.2 – Dados recolhidos e a respetiva descrição.

Fonte: SIVA (2016).

Nome da variável		Descrição	Unidade de Medida
Horas disponíveis na agenda		Número total de horas de presença previstas no local de trabalho, disponíveis na agenda.	Horas-homem (H.h)
Objetivo de horas trabalhadas		Número de horas totais de trabalho que se pretendem realizar.	Horas-homem (H.h)
Objetivo de horas agendadas		Número de horas de trabalho que se pretendem agendar.	Horas-homem (H.h)
Horas agendadas	Agendadas M	Número real de horas de trabalho planeadas na agenda para clientes com marcação.	Horas-homem (H.h)
	Agendadas O	Número real de horas de trabalho planeadas na agenda para ordens de reparação pendentes.	Horas-homem (H.h)
Horas agendadas para dias posteriores		Número de horas de trabalho já agendadas para os dias seguintes.	Horas-homem (H.h)
Horas disponíveis reais		Número total de horas de presença reais no local de trabalho, disponíveis para trabalhar, considerando as faltas e o trabalho suplementar.	Horas-homem (H.h)
Horas trabalhadas (Utilização / Produtividade)	Agendadas M	Número de horas trabalhadas nas viaturas que foram agendadas pela central de marcações, relativas a clientes com marcação.	Horas-homem (H.h)
	Agendadas O	Número de horas trabalhadas nas viaturas que foram agendadas pela central de marcações, relativas a ordens de reparação pendentes.	Horas-homem (H.h)
	Extra M	Número de horas trabalhadas nas viaturas que não foram agendadas pela central de marcações, relativas a clientes sem marcação.	Horas-homem (H.h)
	Extra O	Número de horas trabalhadas nas viaturas que não foram agendadas pela central de marcações, relativas a ordens de reparação pendentes.	Horas-homem (H.h)
Tempo de atividades não produtivas		Número de horas que não agregam valor, ou seja, quando os técnicos não estão a trabalhar nas viaturas. Resulta da diferença entre as horas disponíveis reais e o total de horas trabalhadas.	Horas-homem (H.h)
Horas agendadas que faltaram		Número total de horas de trabalho agendado que na realidade não compareceu na oficina na data agendada.	Horas-homem (H.h)

3.2.3. Desempenho Atual da Oficina Soauto Expo

Numa perspetiva de melhoria contínua é fundamental medir e avaliar o desempenho atual dos trabalhos diários da oficina Soauto Expo, sustentado por medidas de desempenho que permitem perceber qual o seu posicionamento em relação ao desempenho pretendido, recorrendo aos dados recolhidos na secção 3.2.2.

As medidas de desempenho conferem informações acerca da eficácia e eficiência de um sistema, neste caso do serviço de assistência técnica da oficina Soauto Expo, permitindo identificar aspetos críticos e oportunidades de melhoria. São, ainda, fundamentais no apoio à tomada de decisão.

Esta secção corresponde à etapa *Verificar* da metodologia de melhoria contínua seguida nesta dissertação, o ciclo PDCA. Portanto, esta etapa dá seguimento à execução da etapa *Planear* – que assentou no desenvolvimento da agenda oficial – e à etapa *Executar* – relativa ao início da recolha de dados a 14 de fevereiro de 2014.

Nesta secção as medidas de desempenho implementadas estão em vigor na SIVA no âmbito da avaliação das suas oficinas autorizadas e, ainda, estão sustentadas teoricamente (secção 2.1.3.1). Estas medidas estão associadas ao rendimento operacional do serviço, ou seja, relativo ao rendimento das suas atividades diárias, nomeadamente:

- i) taxa de ocupação;
- ii) taxa de utilização de cada tipo de “estado”;
- iii) eficácia da marcação.

3.2.3.1. Taxa de Ocupação

A taxa de ocupação é uma medida de desempenho que se baseia na relação entre a produtividade dos técnicos (total de horas trabalhadas) e a sua presença na oficina (disponibilidade real) no seu respetivo local de trabalho desempenhando as suas funções. Uma taxa de ocupação elevada é uma das principais condições para alcançar a rentabilidade desejada para a oficina.

A taxa de ocupação é calculada através da métrica apresentada na equação (3.1), que corresponde à média dos rácios entre o total de horas trabalhadas e o total de horas disponíveis reais para os n dias.

$$Taxa\ de\ ocupação = \sum_{i=1}^n \left(\frac{Total\ de\ horas\ trabalhadas_ (H.h)}{Total\ de\ horas\ disponíveis\ reais_ (H.h)} \right) / n \quad (3.1)$$

A Figura 3.11. apresenta os valores médios mensais obtidos para esta medida de desempenho com base nos valores diários recolhidos entre 14 de Fevereiro de 2014 e 31 de Março de 2016, inclusive. Apresenta, ainda, o valor objetivo de ocupação e o valor médio das Indústrias Europeias.




Figura 3.11 – Ocupação média mensal dos técnicos da oficina Soauto Expo entre Fevereiro de 2014 e Março de 2016.

Fonte: SIVA (2016) e Stanković et al (2011).

A análise dos resultados permite constatar que a ocupação mensal dos técnicos apresenta um valor médio de 91%. Entre os meses de outubro e novembro de 2015, verificou-se uma ocupação abaixo da ocupação média das indústrias europeias, que corresponde a 90% (Stanković et al., 2011), em cerca de 6% e 5%, respetivamente. Este facto pode resultar da i) ocorrência de tempos mortos resultantes da espera de material, ii) má organização na distribuição do trabalho, iii) definição das horas de trabalho que podem não refletir as horas de trabalho reais do dia (eficácia de agendamento) e iv) pausas excessivas entre tarefas (Stanković et al., 2011).

3.2.3.2. Taxa de Utilização para cada tipo de “Estado”

Tendo em conta a segmentação das horas trabalhadas (ver Figura 3.9, na secção 3.2.1.4.) torna-se importante perceber o trabalho realizado diariamente na oficina que está sujeito a um planeamento prévio para o dia (agendadas para o dia) e o trabalho para o qual não é efetuado o agendamento para o dia, em termos de percentagem.

A taxa de utilização diária para cada “estado”, i) Agendadas M, ii) Agendadas O, iii) Extra M e iv) Extra O, consiste na relação entre as horas trabalhadas para um determinado “estado” e o total de horas disponíveis, a fim de se perceber qual o “estado” com maior taxa de utilização por parte dos técnicos.

Seja X o “estado” que se pretende avaliar, a métrica que quantifica a taxa de utilização diária é determinada através da equação (3.2).

$$\begin{aligned} & \text{Taxa de utilização diária para cada "estado"} \\ &= \frac{\text{Horas trabalhadas para } X \text{ (H.h)}}{\text{Total de horas disponíveis reais (H.h)}} \end{aligned} \quad (3.2)$$

A partir desta métrica resulta o cálculo para os 4 “estados”, ou seja, a taxa de utilização diária para clientes com marcação (agendadas M), ordens de reparação pendentes com marcação (agendadas O), clientes sem marcação (extra M) e ordens de reparação pendentes definidas apenas no dia (extra O), através das equações (3.3), (3.4), (3.5) e (3.6), respetivamente.

$$\begin{aligned} & \text{Taxa de utilização diária para agendadas M} \\ &= \frac{\text{Horas trabalhadas para agendadas M (H.h)}}{\text{Total de horas disponíveis reais (H.h)}} \end{aligned} \quad (3.3)$$

$$\begin{aligned} & \text{Taxa de utilização diária para agendadas O} \\ &= \frac{\text{Horas trabalhadas para agendadas O (H.h)}}{\text{Total de horas disponíveis reais (H.h)}} \end{aligned} \quad (3.4)$$

$$\begin{aligned} & \text{Taxa de utilização diária para Extra M} \\ &= \frac{\text{Horas trabalhadas para extra M (H.h)}}{\text{Total de horas disponíveis reais (H.h)}} \end{aligned} \quad (3.5)$$

$$\begin{aligned} & \text{Taxa de utilização diária para Extra O} \\ &= \frac{\text{Horas trabalhadas para extra O (H.h)}}{\text{Total de horas disponíveis reais (H.h)}} \end{aligned} \quad (3.6)$$

Contudo, também é importante medir a percentagem associada ao tempo de atividades não produtivas. Esta é medida através da taxa de improdutividade diária, que tem como variáveis o tempo associado às atividades não produtivas e o total de horas disponíveis dos técnicos, equação (3.7).

$$\text{Taxa de improdutividade diária} = \frac{\text{Tempo de atividades não produtivas (H.h)}}{\text{Total de horas disponíveis reais (H.h)}} \quad (3.7)$$

A Figura 3.12 apresenta os valores médios anuais obtidos para as taxas de improdutividade e de utilização para clientes com marcação, ordens de reparação pendentes com marcação, clientes sem marcação e ordens de reparação pendentes, com base nos valores diários recolhidos entre 14 de Fevereiro de 2014 e 31 de Março de 2016, inclusive.

A análise de resultados permite constatar que apenas 33% (valor médio) das horas disponíveis na oficina são dedicadas a trabalho agendado para clientes sem marcação – agendadas M. Observou-se, também que as ordens de reparação pendentes não são agendadas previamente, levando a que não haja trabalho realizado neste “estado” – agendadas O. O que significa que 67% das horas disponíveis são dedicadas a trabalho que é definido apenas no próprio dia (trabalho extra) e a atividades não produtivas, das quais cerca de 70% correspondem a ordens de reparação pendentes – extra O, 18% para clientes sem marcação – extra M – e 12% para atividades não produtivas.




Figura 3.12 – Percentagem média anual dos quatro tipos de horas trabalhadas pelos técnicos e da improdutividade entre 2014 e 2016.

Fonte: SIVA (2016).

A Figura 3.13 apresenta a evolução dos valores médios obtidos relativamente à utilização mensal para cada um dos “estados” e à percentagem mensal de improdutividade. Esta evolução permite confirmar que o desempenho, que se observou na Figura 3.12, predomina ao nível mensal, ou seja, apenas cerca de 33% das horas trabalhadas correspondem a trabalho que foi sujeito a um agendamento atempado, enquanto grande parte das horas disponíveis, em média, cerca de 45%, são dedicadas a ordens de reparação pendentes definidas apenas no próprio dia.




Figura 3.13 – Percentagem média mensal da utilização dos técnicos nos quatro tipos de “estado” e da improdutividade entre Fevereiro de 2014 e Março de 2016.

Fonte: SIVA (2016).

Dado que se trata de um serviço prestado diariamente pela oficina é importante ter uma perspetiva semanal da utilização das horas disponíveis para cada “estado”.

Desta forma, a Figura 3.14 apresenta os valores médios para cada dia da semana. A partir da Figura 3.14 pode constatar-se que, em média, a utilização das horas disponíveis para ordens de reparação pendentes definidas no dia aumenta com o decorrer da semana e, no sentido inverso, a utilização das horas disponíveis para clientes com marcação diminui derivado da política de marcações entre a central de marcações e o concessionário. Ou seja, por norma, agenda-se os pedidos de reparação para o início da semana, de modo a que os seus clientes não tenham de ficar privados dos seus veículos para o fim de semana caso ocorra algum imprevisto durante a reparação.

Assim, com o decorrer da semana são utilizadas mais horas disponíveis para ordens de reparação pendentes e que são definidas apenas no próprio dia. De salientar que à segunda-feira existe maior utilização das horas disponíveis para clientes sem marcação e à sexta-feira com o reduzido trabalho que é previamente planeado leva a que haja maior tempo de improdutividade.




Figura 3.14 – Percentagem média por dia da semana dos quatro tipos de horas trabalhadas pelos técnicos e da improdutividade.

Fonte: SIVA (2016).

Através da análise da taxa de utilização, em termos semanais, pode concluir-se que existe uma utilização excessiva das horas disponíveis para ordens de reparação pendentes que não são agendadas com antecedência, de forma a efetuar-se um planeamento rigoroso. Este planeamento antecipado permitiria assegurar a disponibilidade dos equipamentos e instalações, reduzir o tempo de imobilização da viatura e uma melhor organização na distribuição dos trabalhos, de modo a reduzir os tempos de espera elevados (improdutividade elevada).

3.2.3.3. Eficácia do Agendamento

Outro aspeto importante para as operações diárias do serviço de assistência técnica passa pelo conhecimento dos tempos para cada ordem de reparação, de modo a que as marcações sejam as mais rigorosas possíveis.

O conhecimento antecipado dos tempos para cada ordem de reparação é vantajoso já que o excesso de horas marcadas em relação às horas realmente trabalhadas provoca improdutividade e, como consequência, acarreta custos acrescidos. A escassez de horas marcadas pode implicar i) o incumprimento dos prazos de entrega das viaturas aos clientes pelo facto dos técnicos não terem tempo para reparar todas as viaturas agendadas ou ii) em problemas de qualidade por terem de realizar as intervenções em menos tempo do que seria recomendável.

Assim, a escassez de horas marcadas pode estar associado i) ao incumprimento dos tempos de cada ordem de reparação por parte dos técnicos em relação ao que foi marcado ou ii) ao alargamento do âmbito da reparação devido a queixas do cliente apenas na entrega da viatura e não na marcação ou iii) devido às necessidades adicionais verificadas durante a inspeção da viatura.

Assim, a eficácia do agendamento é calculada através da métrica apresentada na equação (3.8).

Eficácia do agendamento

$$= \frac{\text{Horas trabalhadas para agendadas } M_{(H.h)}}{\text{Horas agendadas } M_{(H.h)} - \text{Horas agendadas que faltaram}_{(H.h)}} \quad (3.8)$$

Considera-se um bom agendamento quando a eficácia do agendamento está compreendida entre 0,9 e 1,1, que corresponde a uma diferença entre horas agendadas M e horas trabalhadas para agendadas M de 4 H.h, ou seja, em muitos dos casos inferior a metade de um turno de um técnico (7,5 horas).

A Figura 3.15 apresenta, mensalmente, a ocorrência de valores acima de 1,1 (escasso agendamento), entre 0,9 e 1,1 (bom agendamento) e abaixo de 0,9 (excesso de agendamento), tendo em conta que em cada mês contabiliza 21 ou 22 observações. De salientar que, mesmo com o aumento do volume de trabalhos para clientes sem marcação verificado nos meses de outubro e novembro de 2015 (Figura 3.13), o excesso de agendamento contribui para uma ocupação baixa.




Figura 3.15 – Eficácia do agendamento em termos mensais.

Fonte: SIVA (2016).

3.2.3.4. Conclusão

A ocupação média mensal, por norma, apresenta um valor superior, ou aproximadamente igual, à ocupação média das indústrias europeias (que corresponde a 90%). No entanto, nos meses de outubro e novembro de 2015 registaram-se valores médios de ocupação inferiores à média europeia, ou seja, com uma percentagem considerável de tempos não produtivos, devido à elevada ocorrência de excesso de agendamentos nesses períodos.

Pela taxa de utilização média mensal, verificou-se que apenas 33% (valor médio) das horas atribuídas aos técnicos correspondem a trabalho agendado para clientes com marcação – agendadas M –, existindo uma elevada utilização para ordens de reparação pendentes que não são agendadas com antecedência – extra O –, 45% (valor médio). Observou-se, também, que as ordens de reparação pendentes não são agendadas previamente, resultando em registo de trabalho nulo realizado neste “estado” – agendadas O. Em média, cerca de 13% das horas atribuídas aos técnicos são utilizadas para clientes sem marcação – extra M –, observando-se picos de utilização média nos meses de junho e novembro. Os restantes 9% (valor médio) correspondem a improdutividades, ou seja, à percentagem de horas atribuídas aos técnicos associada a atividades não produtivas.

Pela taxa de utilização média diária, verificou-se que à segunda-feira existe uma maior utilização das horas disponíveis para clientes sem marcação e à sexta-feira com o reduzido trabalho que é planeado previamente implica que haja uma maior percentagem de improdutividade.

Capítulo 4 – Proposta de uma Metodologia de Apoio ao Agendamento e Análise de Resultados

Este Capítulo corresponde à etapa *Atuar* da metodologia de melhoria contínua seguida nesta dissertação, o ciclo PDCA. Portanto, esta etapa dá seguimento à etapa *Verificar*, realizada no Capítulo 3 no sentido de analisar e avaliar do desempenho atual da oficina Soauto Expo.

Assim, este Capítulo identifica algumas oportunidades de melhoria e propõe uma metodologia de apoio ao agendamento que assenta na utilização de um modelo de previsão capaz de modelar as variações diárias da utilização de horas-homem para clientes sem marcação. Depois é efetuado um estudo de vários modelos de previsão, a partir de uma análise cuidada da série cronológica, por forma a determinar o modelo que apresenta maior capacidade preditiva.

No final do Capítulo é apresentado um resumo dos resultados obtidos nas etapas de ajustamento e de validação dos modelos de previsão aplicados, é identificado o modelo de previsão que apresenta maior capacidade preditiva e é efetuada uma análise de sensibilidade, de modo a avaliar se a metodologia de agendamento proposta – que adota o modelo de previsão que apresenta maior capacidade preditiva – apresenta maior rigor face à metodologia de agendamento atualmente em vigor na oficina Soauto Expo.

4.1. Identificação de Oportunidades de Melhoria

Perante a medição e avaliação do desempenho operacional do serviço de assistência técnica da oficina Soauto Expo existe um conjunto de medidas passíveis de adotar para reduzir as improdutividades, nomeadamente:

- A conquista de novos clientes para as oficinas;
- O aumento do número de serviços prestados (por exemplo, oferta de uma lavagem após cada reparação/revisão);
- A atribuição de prémios para os colaboradores da oficina, consoante a sua taxa de ocupação obtida;
- O controlo permanente da qualidade do trabalho;
- E, sobretudo, a melhoria do agendamento diário da oficina.

Nesse sentido, a presente dissertação pretende avaliar e propor uma metodologia de apoio ao agendamento que assenta na avaliação da adequabilidade de um modelo de previsão para a utilização diária de horas-homem para clientes sem marcação (extra M), de forma a definir-se diariamente uma folga destinada ao trabalho que não é possível planear e, assim, estabelecer um objetivo de horas a agendar relativo a pedidos de clientes para reparação/manutenção dos seus veículos e a ordens de reparação pendentes na oficina. Caso os resultados se revelem adequados, a empresa pode desenvolver medidas de ação que permitam resolver os desafios com a maior eficiência possível.

4.2. Processo

A partir dos dados recolhidos (ver secção 3.2.2.) na base de dados da empresa (no *software* DMS), a série cronológica relativa à utilização de horas-homem (H.h) para clientes sem marcação, foi analisada, processada e modelada com recurso a dois tipos de *software*:

- ***MSExcels***, para construir uma base de dados, analisar variáveis, desenvolver modelos de previsão, otimizar os parâmetros destes e desenvolver os testes de diagnóstico necessários através de uma folha de cálculo e das aplicações intrínsecas ao *MSExcels* (*Solver*, ANOVA, Regressão, Correlação, entre outras);
- e ***Minitab***, *software* de estatística, para diminuir a complexidade dos processos e assegurar a precisão dos resultados relativos à análise da função de autocorrelação (FAC) e da função de autocorrelação parcial (FACP) da série cronológica e à utilização de modelos SARIMA, com o objetivo de apoiar a seleção de modelos de previsão, bem como calcular os respetivos testes de diagnóstico i) quanto à adequação do modelo, segundo um teste qui-quadrado com base na estatística de Ljung-Box Q e ii) quanto à importância de cada componente, segundo o *p-value*.

O desenvolvimento do estudo realizado envolve seis fases intrínsecas, Figura 4.1.

Breve descrição de cada fase	
1. Base de Dados	<ul style="list-style-type: none"> • Construção de uma base de dados, de acordo com as variáveis definidas na secção 3.2.2., entre 14 de Fevereiro de 2014 e 31 de Março de 2016.
2. Definição do Horizonte Temporal	<ul style="list-style-type: none"> • Definir as amostras de ajustamento e de validação a usar no desenvolvimento do modelo de previsão.
3. Tratamento dos Dados	<ul style="list-style-type: none"> • Identificação e tratamento de dados omissos e de <i>outliers</i>, relativamente à série em estudo; • Tratamento da série cronológica para operacionalização dos vários modelos.
4. Análise dos Dados	<ul style="list-style-type: none"> • Análise de comportamentos na série cronológica através de métodos estatísticos e gráficos; • Identificação de componentes da série cronológica; • Identificação de possíveis modelos.
5. Modelo de Previsão	<ul style="list-style-type: none"> • Desenvolvimento de modelos de séries cronológicas e causais; • Estimação dos parâmetros dos modelos para a amostra de ajustamento; • Aplicação de medidas estatísticas para quantificar o erro de previsão, tanto para a amostra de ajustamento como para a de validação.
6. Avaliação dos modelos	<ul style="list-style-type: none"> • Resumo das medidas estatísticas que quantificam o erro de previsão de cada modelo para as amostras de ajustamento e de validação; • Análise de sensibilidade dos modelos aos dados diários e da sua operacionalidade, e da metodologia de agendamento proposta face à metodologia de agendamento atualmente em vigor.
7. Controlo e Monitorização	<ul style="list-style-type: none"> • Propostas de medidas a adotar com vista ao controlo e à melhoria contínua do modelo.

Figura 4.1 – Metodologia utilizada no desenvolvimento do modelo de previsão.

4.2.1. Objetivos do Modelo de Previsão

A aplicação da metodologia apresentada na Figura 1.1 tem como objetivo adotar um modelo de previsão capaz de contemplar as variações diárias da utilização de horas-homem para clientes sem marcação (extra M).

De modo a identificar o modelo que melhor se ajusta ao comportamento da variável, foram estudados vários modelos de séries cronológicas e causais, com base numa análise preliminar do comportamento da variável ao longo do tempo e perante a influência de variáveis associadas às fases de agendamento.

Assim, o principal objetivo do estudo consiste em desenvolver um modelo de previsão e analisar a sua adequabilidade com a perspetiva de implementá-lo como apoio ao agendamento. Pretende-se melhorar o agendamento através da definição diária do número de horas dos técnicos que são dedicadas a trabalhos não agendados/planeados. Portanto, de modo a estabelecer o objetivo de horas a agendar para determinado dia, pretende-se definir a folga na agenda para trabalhos de clientes que aparecem no próprio dia a solicitar os serviços de assistência técnica e, por isso, não realizaram qualquer marcação prévia.

A Figura 4.2 esquematiza a proposta de metodologia de apoio ao agendamento que se pretende implementar na 1ª fase do agendamento (definição de objetivos), isto é, o objetivo de horas a agendar, definido a partir da previsão da folga de cada dia, uma vez que o objetivo de horas a trabalhar está previamente definido (95% das horas disponíveis na agenda).

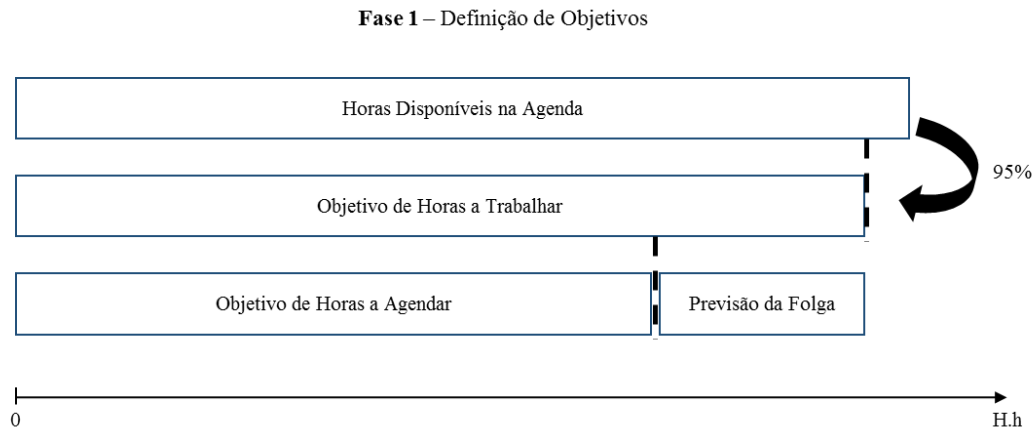


Figura 4.2 – Proposta de metodologia de apoio ao agendamento.

4.2.2. Horizonte Temporal e Recolha de Dados

A metodologia que se pretende empreender para melhorar o agendamento é desenvolvida a fim de ter um impacto na afetação de recursos humanos e na parametrização de necessidades logísticas das operações diárias de reparação/manutenção da concessionária Soauto Expo, por isso, o modelo de previsão inserido nesta metodologia é aplicado apenas no curto prazo.

A recolha de dados foi realizada com base nas variáveis mencionadas na secção 3.2.2., entre 14 de Fevereiro de 2014 e 31 de Março de 2016. No entanto, o estudo da evolução da utilização de horas-homem para clientes sem marcação foi desenvolvido com base no horizonte temporal de 1 de Janeiro de 2015 a 31 de Março de 2016, contendo um total de 326 observações, considerando-se suficiente para identificar e captar certos comportamentos de utilização de horas-homem para clientes sem marcação. Este estudo foi concretizado com recurso a modelos de previsão.

A análise dos diferentes modelos consistiu na metodologia da validação cruzada (Jennings et al., 2015) – a Figura 4.3 esquematiza como se procedeu. Foi definida uma amostra de ajustamento, que compreende o horizonte temporal de 1 de Janeiro de 2015 a 31 de Março de 2016 (326 observações), com vista à otimização dos parâmetros dos diferentes modelos. Posteriormente, recolheu-se uma amostra de validação, que compreende o horizonte temporal de 1 de Abril de 2016 a 31 de Maio de 2016 (43 observações), com o objetivo de analisar a precisão dos modelos ajustados.




Figura 4.3 – Definição da amostra de ajustamento e de validação.

4.2.3. Tratamento dos Dados

Uma análise preliminar dos dados recolhidos permite identificar a existência de valores extremos (*outliers*) e de valores nulos, que têm de ser tratados antes de se iniciar a modelação dos dados. A Figura 4.4 apresenta a série cronológica da utilização de H.h para clientes sem marcação, observando-se logo à partida a existência de valores nulos, que correspondem aos dias em que a oficina não operou por se tratarem de feriados.




Figura 4.4 – Série cronológica da utilização de H.h para clientes sem marcação.

i) *Outliers*

Antes de ajustar um modelo de previsão à amostra de ajustamento procedeu-se à identificação e remoção de *outliers* (valores extremos ou atípicos), de modo a assegurar a integridade dos dados recolhidos e não influenciar o processo de ajustamento do modelo, bem como, das análises estatísticas inerentes ao processo. Para identificar os *outliers* aplicou-se o teste

estatístico *Box-plot* em detrimento de um teste da normalidade, uma vez que a definição dos limites não é afetada pela presença de valores extremos. Este teste foi aplicado à variável em estudo, utilização diária de H.h para clientes sem marcação, duas vezes, nomeadamente:

- 1º. às observações, de forma a detetar valores extremos ou *outliers*;
- 2º. e, posteriormente, às diferenças sazonais de período 5 ($Y'_t = Y_t - Y_{t-5}$), com o objetivo de detetar variações elevadas e incomuns para o mesmo dia da semana.

A Figura 4.5 assinala os 4 *outliers* identificados pelo teste *Box-plot*. No Anexo II, nas Tabelas II.1 e II.2, encontram-se as estatísticas e a informação dos valores atípicos que resultaram da aplicação do teste.




Figura 4.5 – Outliers identificados na série cronológica (sem os valores nulos) através do teste *Box-plot*.

De acordo com o teste *Box-plot* apenas foram detetados valores extremos, não se detetando variações incomuns. Dos quatro *outliers* identificados, um deles é extremo e os restantes são significativos. Como se observa na Figura 4.5, são valores muito elevados, acima de 30 H.h, correspondendo a mais de 4 técnicos (turno de 7,5h por técnico) trabalharem para clientes sem marcação nestes dias, respetivamente 6, 5, 7 e 6 técnicos (por ordem cronológica da Figura 4.4). Este facto pode estar relacionado com o excesso de técnicos para o volume de trabalhos devido ao modo como foi realizada a distribuição dos trabalhos, o que pode ter gerado valores extremos em relação à média de utilização de H.h para clientes sem marcação, que se situa nas 19 H.h, ou seja, em média menos de 3 técnicos (cada um com 7,5h de trabalho por dia).

Assim, decidiu-se substituir estes valores e através da estimativa de 4 novos valores para os dias em causa com base na média entre os períodos homólogos anterior e o posterior do dia de semana em causa para, no caso de existir sazonalidade, esta não ser mascarada. Foram modificadas apenas 1,2% das 326 observações da série cronológica em estudo.

A série de dados com os *outliers* tratados apresenta um valor médio de 12,83 H.h, um desvio padrão de 6,69 H.h, um valor máximo de 32,02 H.h e um valor mínimo de 0 H.h.

ii) Valores nulos

Relativamente aos valores nulos da série cronológica, estes correspondem aos dias em que a oficina do concessionário Soauto Expo não operou, devido à ocorrência de feriados, correspondendo a 10 observações. Por isso, para o desenvolvimento dos modelos de previsão baseados nas séries cronológicas, nomeadamente AES com Sazonalidade, *Holt-Winters* e SARIMA, foram estimadas 10 observações com base na média dos períodos homólogos anterior e posterior do dia da semana em causa, exatamente pela razão. Foram estimadas 3,1% das 326 observações da série em estudo. Portanto, na globalidade foram estimadas 4,3% (14 observações) das 326 observações no tratamento da série para o desenvolvimento dos modelos de previsão.

Assim, a série de dados com os *outliers* e os valores nulos tratados apresenta um valor médio de 13,23 H.h, um desvio padrão de 6,34 H.h, um valor máximo de 32,02 H.h e um valor mínimo de 0,42 H.h.

4.3. Análise da Série Cronológica

A Figura 4.6 apresenta a série cronológica diária da utilização de H.h para clientes sem marcação já tratada entre 1 de Janeiro de 2015 e 31 de Março de 2016, correspondendo a um total de 326 observações. Verifica-se que o comportamento desta variável, utilização de H.h para clientes sem marcação, não é constante ao longo do tempo, existindo picos de utilização e diminuições consideráveis em certos períodos. Observa-se, ainda, uma ténue tendência negativa, portanto, a série cronológica é não estacionária, em média.




Figura 4.6 – Série cronológica da utilização de H.h para clientes sem marcação – amostra de ajustamento.

A série de dados da Figura 4.6 apresenta um valor médio de 13,23 H.h, um desvio padrão de 6,34 H.h, um valor máximo de 32,02 H.h e um valor mínimo de 0,42 H.h.

Por forma a identificar certos comportamentos que podem estar presentes na série cronológica foi determinada a função de autocorrelação (FAC) da amostra de ajustamento (Figura 4.7), utilizando o *software Minitab*. Pode observar-se a existência de uma forte correlação positiva no *lag* 1 e no *lag* 2, que sugere a influência residual dos período $t - 1$ e $t - 2$ (e que pode indicar, no caso dos modelos ARIMA, mais precisamente no processo de média móvel, $q = 2$, ou seja, MA(2)). Nos *lags* 5, 10, 15, 20 e 25 existe também uma forte correlação positiva que aponta para uma influência sazonal de 5 períodos, observando-se, ainda, nestes *lags*, um decaimento lento para zero, o que evidencia a não estacionária, em média, e sugere uma diferenciação de 1ª ordem para remover esta componente, para que se possa observar outras estruturas de correlação antes de se proceder ao ajuste dos modelos (Makridakis et al., 1998).




Figura 4.7 – Função de autocorrelação da série cronológica (amostra de ajustamento – 4,3% dos dados modificados).

A FAC da série diferenciada, $Y'_t = Y_t - Y_{t-1}$, (diferenciação de 1ª ordem) apresentada na Figura 4.8, evidencia uma forte correlação nos *lags* 5, 10, 15, 20, 25, 35 e 55, o que confirma e sugere a existência de uma influência sazonal de período 5. Observa-se, também uma forte correlação no *lag* 1, que sugere a influência residual do período $t - 1$. Estes factos podem indicar, no caso dos modelos SARIMA, nomeadamente no processo integrado de média móvel dos termos não sazonais, $d = 1$ e $q = 1$, ou seja, IMA(1,1) e no processo integrado de média móvel dos termos sazonais, $D = 1$ e $Q = 1$, ou seja, SIMA(1,1).




Figura 4.8 – Função de autocorrelação da série cronológica (amostra de ajustamento – 4,3% dos dados modificados) com diferenciação de 1ª ordem.

4.4. Modelos de Previsão a Analisar

A partir deste estudo preliminar para detetar padrões existentes na série cronológica, constata-se a não *estacionaridade* da série, em média, (apesar de ser ténue a tendência negativa que apresenta), uma grande variabilidade associada e a presença de sazonalidade semanal.

Nesse sentido, os modelos de séries cronológicas mais adequados são i) o modelo de Alisamento Exponencial Simples com Sazonalidade que apesar de não modelar a tendência, e sendo esta muito ténue, a ponderação associada ao erro do período homólogo anterior pode conseguir modelar esta componente, ii) o modelo de *Holt-Winters*, e iii) os modelos Sazonais de *Autoregressão* Integrada de Médias Móveis com sazonalidade de períodos 5 (modelos SARIMA).

Considerou-se importante estudar esta série à luz de um modelo causal, como é caso do modelo de regressão linear múltipla, devido ao facto da variabilidade presente na variável utilização de H.h para clientes sem marcação, variável a explicar/modelar poder ser influenciada pelas fases de agendamento e, também, por uma certa sazonalidade anual.

Com base no tratamento dos dados, secção 4.2.3., a Figura 4.9 apresenta a amostra de ajustamento que foi utilizada no ajuste dos quatro modelos mencionados anteriormente.

Os modelos foram desenvolvidos com recurso ao *software MSEExcel*, à exceção dos modelos SARIMA, que foram desenvolvidos no *software Minitab* para reduzir a complexidade de aplicação.

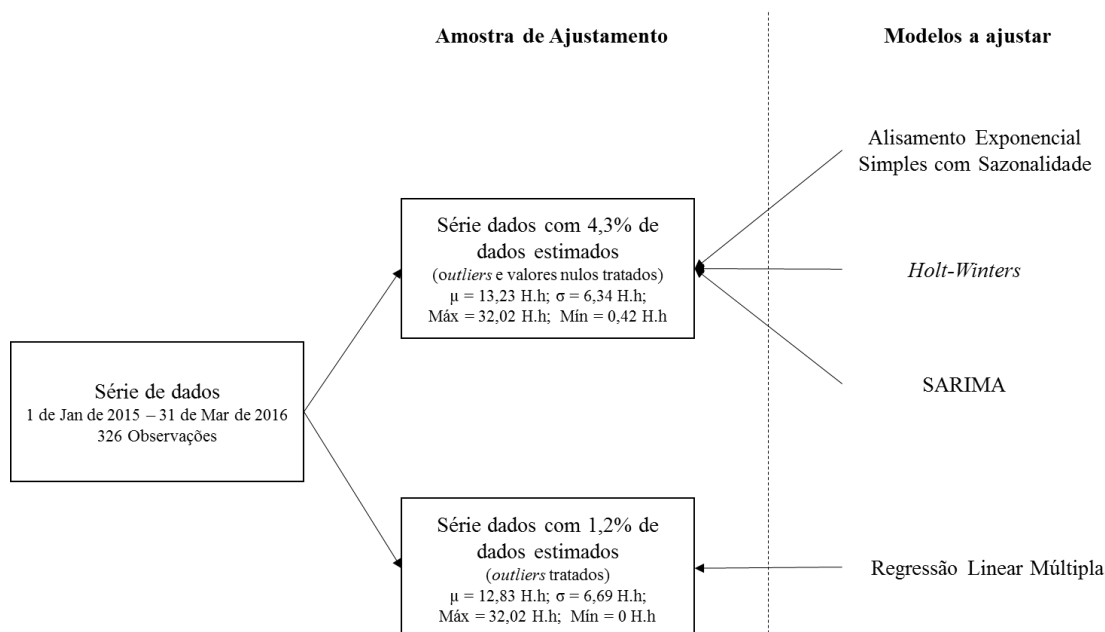


Figura 4.9 – Tipo de amostra de ajustamento para os modelos a analisar.

No caso dos modelos de séries cronológicas desenvolvidos no *MSEExcel* recorreu-se ao *solver* para otimizar as constantes de alisamento e coeficientes na fase de ajustamento. No modelo causal, para estudar correlações e obter os coeficientes de regressão, recorreu-se à ferramenta *Analysis Tool Pack* disponibilizada no *MSEExcel*.

Após o ajustamento, é feita a validação de cada modelo utilizando a amostra de validação, Figura 4.10.




Figura 4.10 – Série cronológica da utilização de H.h para clientes sem marcação – amostra de validação.

Nas etapas de ajustamento e de validação avaliou-se a capacidade preditiva de cada modelo com base nas estatísticas de erro, erro médio (EM), erro absoluto médio (EAM), raiz do erro quadrático médio (REQM), erro percentual absoluto médio (EPAM) e, ainda, no coeficiente de determinação (estatística R^2) e no teste *Bias* ao EM.

Verificou-se que quanto mais próximo o EPAM for de 0% e quanto maior for a estatística R^2 maior será a capacidade do modelo para estimar a utilização de H.h para clientes sem marcação.

De salientar que tanto no ajustamento como na validação, é fornecida também a estatística DPA (desvio padrão da amostra utilizada).

4.5. Etapa de Ajustamento

Esta seção apresenta os resultados obtidos no ajustamento dos modelos de previsão i) de séries cronológicas (Alisamento Exponencial Simples com Sazonalidade, *Holt-Winters* e SARIMA), relativamente às constantes de alisamento e coeficientes ajustados e à sua capacidade preditiva; e ii) de séries causais (regressão linear múltipla), relativamente ao estudo de correlações, aos coeficientes de regressão ajustados e à sua capacidade preditiva.

4.5.1. Modelo Alisamento Exponencial Simples com Sazonalidade

Ao longo da série cronológica verifica-se uma tendência linear negativa que é muito ténue. Desta forma, a constante de alisamento associada ao erro de previsão do período homólogo anterior $t - 5$, isto é, 5 períodos antes, pode conseguir modelar essa componente. Por exemplo, se se verificar uma diminuição do valor real para o período t e a previsão para esse período tiver sido superior, a previsão para o próximo período homólogo $t + 5$ (isto é, 5 períodos posteriores) já terá em consideração o erro associado à redução do valor real do período t em relação ao valor de previsão do período t .

O ajustamento do modelo, isto é, a determinação da constante de alisamento, foi feito usando a amostra de ajustamento. Para a inicialização do modelo atribuiu-se para os primeiros 5 valores de previsão o mesmo valor que o valor real de utilização de H.h dos respetivos períodos. Para otimizar a constante de alisamento (α) recorreu-se ao *solver* no *MSEExcel*, tendo como função objetivo a minimização da REQM e como restrições a constante ser positiva e menor ou igual a 1 ($0 < \alpha < 1$).

Com a estimação da constante de alisamento pelo método dos quadrados mínimos o modelo desenvolvido na etapa de ajustamento é apresentado na equação (4.1).

$$P_t = P_{t-5} + 0,195 \cdot (Y_{t-5} - P_{t-5}) \quad (4.1)$$

Nas Tabelas 4.1 e 4.2 seguintes são apresentados alguns resultados da precisão dos valores estimados pelo modelo comparativamente aos valores da amostra de ajustamento.

Tabela 4.1 – Resultados obtidos no ajuste do modelo AES com sazonalidade.

Estatísticas		Resultados
Amostra de ajustamento	DPA (H.h)	6,337
	Parâmetros	$\alpha = 0,195$
Modelo	Estadísticas de erro	EM (H.h)
		EAM (H.h)
		REQM (H.h)
		EPAM
		R^2
		0,370
		4,823
		6,068
		64 %
		17 %

Tabela 4.2 – Teste do Bias ao erro médio (AES com sazonalidade; etapa de ajustamento).

	$ Z_{calculado} $	$ Z_{0,05} $	
Teste Bias ao EM	1,084	1,645	Não se encontra enviesado

O teste *Bias* ao EM permite concluir que os erros de previsão estão distribuídos normalmente com uma média de 0 para um nível de significância de 5%. Significa que o ajuste do modelo não se encontra enviesado, ou seja, os erros de previsão são tanto por excesso como por defeito e, por isso, a soma dos erros é significativamente aproximada de zero.

Os resultados das estatísticas do erro de previsão mostram que o modelo revela uma capacidade preditiva baixa, embora consiga modelar ligeiramente a variabilidade presente na amostra de ajustamento. A constante de alisamento apresenta um valor baixo, o que significa que o modelo é pouco reativo. O modelo não modela adequadamente o nível, como se observa na




Figura 4.11. O ajustamento não se encontra enviesado, no entanto, o modelo de AES com sazonalidade apenas consegue modelar 17% da variabilidade dos dados, apresentando um valor do EPAM elevado.

Constata-se uma limitação deste modelo em modelar os valores da variável mais elevados e mais reduzidos. De facto, este modelo é mais adequado para séries estacionárias.

4.5.2. Modelo de *Holt-Winters*

Perante os padrões identificados i) não *estacionaridade* da série, em média, (apesar de ser ténue a tendência negativa que apresenta), ii) grande variabilidade associada e iii) presença de sazonalidade semanal, ajustou-se o modelo *Holt-Winters*, uma vez que modela a componente sazonal, o nível e a tendência. Neste sentido, recorreu-se ao *solver* no *MSEExcel*, para otimizar as três constantes de alisamento associadas ao modelo, α , β e γ , tendo como função objetivo a minimização da REQM e como restrições cada uma das constantes ser não negativa e inferior ou igual a 1 ($0 \leq \alpha \leq 1 \wedge 0 \leq \beta \leq 1 \wedge 0 \leq \gamma \leq 1$).

Nas Tabelas 4.3 e 4.4 são apresentados os resultados relativos à qualidade do ajustamento.

Tabela 4.3 – Resultados obtidos do ajuste do modelo *Holt-Winters*.

Estatísticas		Resultados	
Amostra	DPA (H.h)	6,337	
Modelo	Parâmetros	$\alpha =0,099$; $\beta =0$; $\gamma =0,119$	
	Estatísticas de erro	EM (H.h)	0,249
		EAM (H.h)	4,630
		REQM (H.h)	5,869
		EPAM	58 %
R^2		30 %	

Tabela 4.4 – Teste do Bias ao erro médio (*Holt-Winters*; etapa de ajustamento).

	$ Z_{calculado} $	$ Z_{0,05} $	
Teste do Bias ao EM	0,754	1,645	Não se encontra enviesado

Através da Tabela 4.3 constata-se que a constante de alisamento da tendência, β , é 0, de modo a obter a REQM mínima, uma vez que a tendência identificada (na secção 4.3.) é muito ténue, sendo modelada pelas constantes de alisamento do nível e da sazonalidade, α e γ .

Com a observação dos resultados das Tabelas 4.3 e 4.4 pode-se verificar que o modelo não se encontra enviesado e que houve uma ligeira redução das estatísticas do erro de previsão, comparativamente ao modelo de Alisamento Exponencial Simples com Sazonalidade. Porém, os valores extremos não são ajustados adequadamente. Este modelo apenas consegue explicar 30%

da variabilidade presente nos dados e apresenta um EPAM elevado. Na Figura 4.12 observa-se os valores estimados pelo modelo sobrepostos aos valores reais da amostra de ajustamento.




Figura 4.12 – Valores reais da amostra de ajustamento e valores estimados pelo modelo Holt-Winters ($\alpha=0,099$; $\beta=0$; $\gamma=0,119$).

Com a estimação das 3 constantes de alisamento pelo método dos quadrados mínimos o modelo de *Holt-Winters* ajustado encontra-se nas equações (4.2), (4.3), (4.4) e (4.5).

$$P_{t+p} = (L_t + pT_t)S_{t-5+p} = L_t \cdot S_{t-5+p} \quad (4.2)$$

$$L_t = 0,099 \frac{Y_t}{S_{t-5}} + (1 - 0,099)(L_{t-1} + T_{t-1}) \quad (4.3)$$

$$T_t = 0(L_t - L_{t-1}) + (1 - 0)T_{t-1} = 0 \quad (4.4)$$

$$S_t = 0,119 \frac{Y_t}{L_t} + (1 - 0,119)S_{t-5} \quad (4.5)$$

A equação (4.2) permite determinar a previsão da utilização de H.h para clientes sem marcação para o dia $t + p$.

4.5.3. Modelo SARIMA

Com a aplicação da metodologia *Box-Jenkins* procurou-se reduzir a dispersão do erro de previsão através da análise das FAC e FACP, por forma a identificar um modelo que apresente um melhor ajustamento aos dados da amostra.

As Figuras 4.13 a) e 4.13 b) apresentam o comportamento das FAC e FACP da amostra de ajustamento. No gráfico da FAC observa-se um decaimento lento, o que sugere a diferenciação da série no sentido de remover a não *estacionaridade*, em média.

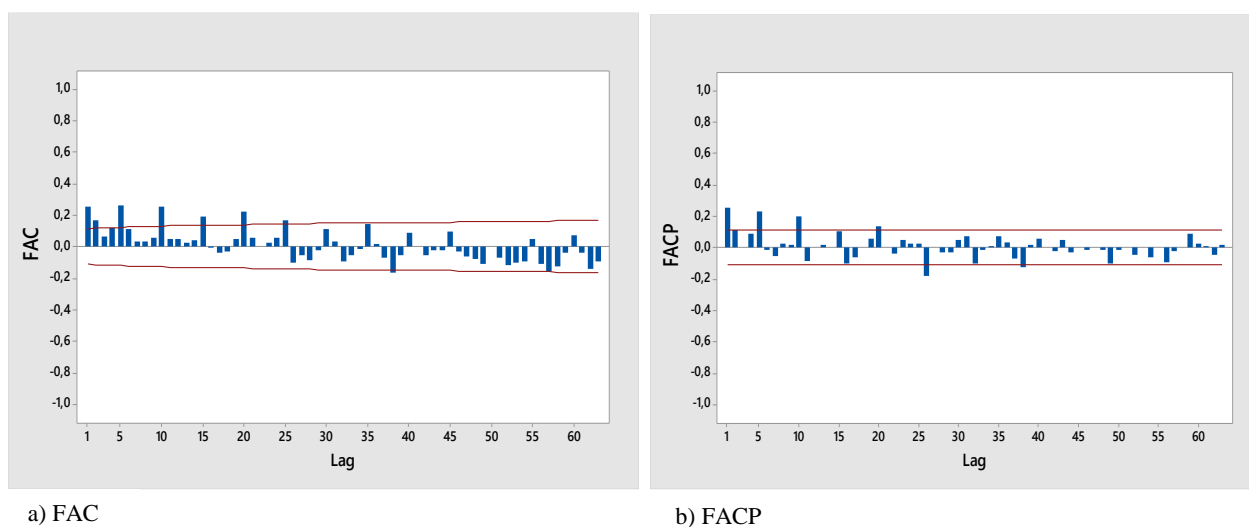
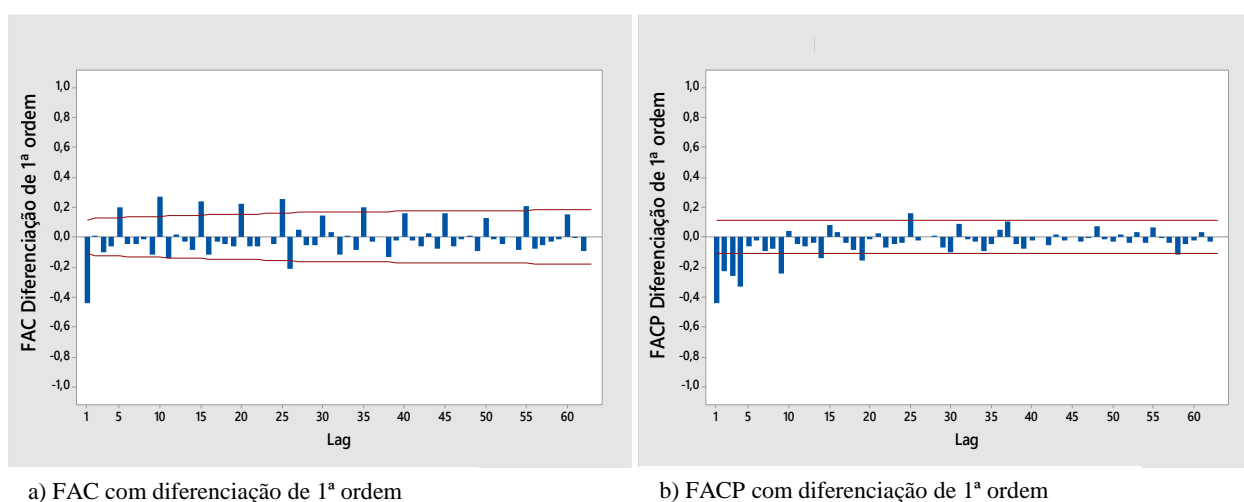


Figura 4.13 – FAC e FACP da série de ajustamento.

Nas Figuras 4.14 a) e 4.14 b) mostra-se as FAC e FACP da amostra de ajustamento com diferenciação de 1ª ordem (amostra diferenciada). Na FAC observa-se a forte correlação nos lags 1, 5, 10, 15, 20, 25, 26, 35 e 55 e na FACP existe uma correlação forte nos primeiros 4 lags, sugerindo no processo *autoregressivo* integrado de médias móveis dos termos não sazonais, $p = 0$, $d = 1$ e $q = 1$, ou seja, $ARIMA(0,1,1)$ e uma diferenciação sazonal de período 5 da amostra diferenciada.



Após a diferenciação de 1ª ordem e sazonal de 5 períodos, obteve-se as Figuras 4.15 a) e 4.15 b) para as FAC e FACP. A diferenciação realizada, ao tornar a amostra estacionária, pela análise das Figuras sugere a utilização de um modelo SARIMA(0,1,1)(0,1,1)₅.




Figura 4.15 – FAC e FACP da série de ajustamento com diferenciação de 1ª ordem e 5ª ordem.

Apesar das FAC e FACP sugerirem um modelo SARIMA(0,1,1)(0,1,1)₅ para a amostra de ajustamento, foram analisados outros modelos SARIMA, nomeadamente, (1,1,1)(1,1,1)₅, (1,1,1)(0,1,2)₅ e (1,1,1)(0,1,1)₅ com o objetivo de reduzir o erro quadrático médio (EQM).

Na Tabela 4.5, são apresentados, de modo sucinto, os resultados obtidos a partir do *software Minitab*. No Anexo II, nas Figuras II.1, II.2, II.3 e II.4, encontram-se os resultados mais detalhados em relação aos 4 modelos analisados.

Tabela 4.5 – Resultados obtidos no ajuste de modelos SARIMA à amostra de ajustamento.

Resultados	Modelos			
	(0,1,1)(0,1,1) ₅	(1,1,1)(1,1,1) ₅	(1,1,1)(0,1,2) ₅	(1,1,1)(0,1,1) ₅
n (nº de observações residuais)	318	316	316	317
r (nº de coeficientes)	2	4	4	3
Erro Quadrático, EQ (H.h)	10041,3	9840,2	9966,3	9874,2
EQM (H.h)	31,6	31,1	31,5	31,2
Teste de <i>Ljung-Box</i>	Adequado	Adequado	Adequado	Adequado
Coefficientes significativamente diferentes de zero	Todos	Nem todos (componente	Nem todos (componente	Todos

		SAR 5 pouco significativa)	SMA 10 pouco significativa)	
Critério de Informação de Akaike, AIC	3,466	3,463	3,475	3,459

Relativamente, aos resultados apresentada na Tabela 4.5, pode concluir-se que o modelo que minimiza o EQM e que apresenta o menor AIC (apesar de nenhum AIC ser significativamente diferente para concluir quanto ao modelo mais simples através do princípio da parcimónia) é o modelo SARIMA(1,1,1)(0,1,1)₅. A estimação dos coeficientes deste modelo através do *software Minitab* (que assumiu como critério o método dos mínimos quadrados), conduziu ao modelo definido pela equação (4.7). Esta resultou da equação equivalente (4.6), que simplifica a identificação das componentes e os coeficientes do modelo ao recorrer-se ao operador de atraso de 1 e 5 períodos, respetivamente B e B^5 , tanto aplicado ao valor de previsão do período t (Y_t) como ao erro de previsão do período t (ε_t).

$$(1 - 0,162B)(1 - B)(1 - B^5)Y_t = (1 - 0,889B)(1 - 0,960B^5)\varepsilon_t \quad (4.6)$$

A equação (4.6) encontra-se abreviada e para a sua aplicação deve estar escrita na sua fórmula geral. Assim, resultou na equação equivalente (4.4).

$$Y_t = Y_{t-1} + Y_{t-5} - Y_{t-6} + 0,162(Y_{t-1} + Y_{t-2} - Y_{t-6} - Y_{t-7}) - 0,889\varepsilon_{t-1} - 0,960\varepsilon_{t-5} + 0,853\varepsilon_{t-6} + \varepsilon_t \quad (4.7)$$

A equação (4.7) permite determinar a previsão da utilização de H.h para clientes sem marcação para o dia t (Y_t), a partir dos i) valores de previsão dos períodos anteriores $t - 1$, $t - 2$, $t - 5$, $t - 6$ e $t - 7$, respetivamente Y_{t-1} , Y_{t-2} , Y_{t-5} , Y_{t-6} e Y_{t-7} , e ii) erros de previsão dos períodos t , $t - 1$, $t - 5$ e $t - 6$, respetivamente ε_t , ε_{t-1} , ε_{t-5} e ε_{t-6} , sendo ε_t , logicamente, igual a zero.

Uma vez que as estimativas obtidas para os coeficientes eram estatisticamente diferentes de zero, procedeu-se ao diagnóstico do modelo. Recorrendo, ainda ao *software Minitab*, determinou-se a FAC dos resíduos, Figura 4.16, para verificar se existe apenas ruído branco. Constatou-se uma ligeira correlação no *lag* 26 e no *lag* 39, mas no computo geral o modelo consegue modelar as diversas componentes existentes.




Figura 4.16 – Função de autocorrelação dos resíduos do modelo $SARIMA(1,1,1)(0,1,1)_5$.

Na Tabelas 4.6 e 4.7 encontram-se os resultados obtidos do ajuste do modelo $SARIMA(1,1,1)(0,1,1)_5$ à amostra de ajustamento com base nas estatísticas do erro, na estatística R^2 e no teste do *Bias* ao EM.

Tabela 4.6 – Resultados obtidos do ajuste do modelo $SARIMA(1,1,1)(0,1,1)_5$.

Estatísticas		Resultados	
Amostra	DPA (H.h)	6,337	
Modelo	Estatísticas de erro	EM (H.h)	0,208
		EAM (H.h)	4,430
		REQM (H.h)	5,561
		EPAM	53,14 %
	R^2	29 %	

Tabela 4.7 – Teste do *Bias* ao erro médio (ARIMA; etapa de ajustamento).

	$ z_{calculado} $	$ z_{0,05} $	
Teste do <i>Bias</i> ao EM	0,665	1,645	Não se encontra enviesado

Os resultados das estatísticas do erro de previsão mostram um EM não enviesado e a redução das estatísticas residuais dos modelos AES com Sazonalidade e *Holt-Winters*.

Contudo o modelo SARIMA(1,1,1)(0,1,1)₅ apresenta uma capacidade preditiva média-baixa, conseguindo modelar apenas 29% do comportamento da amostra de ajustamento. Este facto é perceptível na Figura 4.17, onde a amplitude dos valores ajustados é muito menor do que amplitude dos valores reais.




Figura 4.17 – Valores reais da amostra de ajustamento e valores estimados pelo modelo SARIMA(1,1,1)(0,1,1)₅.

4.5.4. Modelo de Regressão Linear Múltipla

O modelo de regressão linear múltipla é um método estatístico que pode ser usado para analisar a relação entre uma variável dependente, neste caso, a utilização de H.h diárias para clientes sem marcação, e várias variáveis independentes, ou seja, os fatores que influenciam o comportamento da variável dependente em causa.

Com base na Figura 3.10, analisou-se a influência da Fase 1 – para definição dos objetivos – e da Fase 2 – para marcações e planeamento dos recursos – na utilização de H.h diárias para clientes sem marcação, pois a fase de agendamento pode levar a que nem todos os clientes que chegam diariamente à oficina sem marcação prévia possam ser aceites.

Ao não se registar por parte da concessionária o número de clientes sem marcação que são rejeitados e o respetivo número de H.h perdidas, torna-se relevante analisar a influência destas duas fases de agendamento na utilização de H.h para clientes sem marcação, uma vez que pode explicar a grande variabilidade presente nos dados.

i) Análise de correlação de variáveis quantitativas

Efetuiu-se uma análise de correlação linear entre a utilização de H.h para clientes sem marcação e as variáveis i) horas disponíveis na agenda, ii) horas não preenchidas para marcação e iii) horas agendadas para dias posteriores relativas às duas fases de agendamento.

Relembra-se que o número de horas não preenchidas para marcação do determinado dia advém da diferença entre o objetivo de horas agendadas para esse dia e as horas efetivamente agendadas para o dia. O estudo destas variáveis é importante, pois podem explicar a rejeição de clientes sem marcação.

Estudou-se, ainda, a influência da variável tempo (tendência) na série dos dados.

Para determinar se a correlação linear entre a utilização de H.h para clientes sem marcação e as variáveis mencionadas é significativa, aplicou-se o teste de normalidade com base no coeficiente de correlação de *Pearson* para um nível de significância de 5%. Os resultados são apresentados na Tabela 4.8.

Tabela 4.8 – Análise de correlação de variáveis quantitativas.

Variáveis	Coefficiente de correlação de <i>Pearson</i>	$Z_{calculado}$	$ Z_{0,05} $	Correlação
Horas disponíveis na agenda	0,427	8,503	1,645	Significativa
Horas não preenchidas para marcação	0,271	5,061		Significativa
Horas agendadas para dias posteriores	-0,102	-1,840		Significativa
Tempo	-0,125	-2,277		Significativa

Na Tabela 4.8, verifica-se que existe uma forte correlação positiva entre as horas disponíveis na agenda e a utilização de H.h para clientes sem marcação, como seria expectável. Esta constatação permite afirmar que ao agendar-se menos horas-homem para o dia, ou seja, menos técnicos designados para o dia, diminui a utilização de H.h relativa a clientes sem marcação. De certo modo, pode explicar alguma variabilidade derivada das H.h perdidas relativas à rejeição de clientes sem marcação.

As horas não preenchidas para marcação apresentam também uma correlação positiva com a variável dependente, ou seja, quando se marca ordens de reparação (horas agendadas) e se preenche quase na totalidade, de acordo com o objetivo de horas agendadas, leva à redução das horas não preenchidas para marcação o que implica uma diminuição nas H.h para clientes sem marcação. Significa que ao se perspetivar para o dia uma grande volume de H.h para clientes com marcação eleva o risco de rejeição de clientes sem marcação, que se constata com a diminuição da utilização de H.h para clientes sem marcação.

No que diz respeito a ordens agendadas para dias posteriores, que corresponde à variável horas agendadas para dias posteriores, constata-se que a variável tem uma correlação negativa significativa com a variável dependente, isto é, quanto mais horas estiverem agendadas para dias posteriores menor será a utilização de H.h para clientes sem marcação.

Consequentemente, o aumento do número de horas agendadas para dias posteriores pode levar a uma elevada ocupação dos técnicos para ordens de reparação agendadas e, naturalmente, conduzir a um aumento do risco de rejeição de clientes sem marcação, uma vez que existe redução da utilização de H.h para este tipo de clientes.

Como já foi analisado e constatado na secção 4.3., a série cronológica da variável dependente, utilização de H.h para clientes sem marcação, é não estacionária, em média, apresentando uma tendência negativa muito ténue ao longo do tempo. A partir do teste aplicado (Tabela 4.8) confirma-se que existe uma correlação negativa significativa entre a utilização de H.h para clientes sem marcação e o tempo (de dia para dia).

ii) Análise de variáveis “dummy”

No desenvolvimento do modelo de regressão linear múltipla é necessário incluir a influência da componente sazonal semanal, identificada na secção 4.3.

Para modelar a sazonalidade semanal de 5 dias utilizou-se, inicialmente, 4 “dummys”, D_1 , D_2 , D_3 e D_4 que modelam este efeito na segunda, terça, quarta e quinta-feira:

- se for segunda-feira, $D_1=1$, $D_2=0$, $D_3=0$ e $D_4=0$;
- se for terça-feira, $D_1=0$, $D_2=1$, $D_3=0$ e $D_4=0$;

- se for quarta-feira, $D_1=0$, $D_2=0$, $D_3=1$ e $D_4=0$;
- e se for quinta-feira, $D_1=0$, $D_2=0$, $D_3=0$ e $D_4=1$.

No entanto, verificou-se que as “*dummys*” D_2 , D_3 e D_4 relativas a terça, quarta e quinta-feira têm um *p-value* superior a 0,05, o que significa que os três coeficientes são estatisticamente não significativos, e a “*dummy*” D_1 relativa a segunda-feira tem um *p-value* inferior a 0,05, o que significa que o coeficiente é estatisticamente significativo, como se pode observar na Tabela 4.10.

Assim, de forma a incorporar a influência de um feriado à segunda-feira, que implica um valor elevado de utilização H.h para clientes sem marcação à terça-feira, acrescentou-se o este efeito à “*dummy*” D_1 :

- se for segunda-feira e não for feriado, $D_1=1$;
- se for segunda-feira e for feriado, $D_1=0$, então no dia seguinte (terça-feira), $D_1=1$;
- as restantes situações, $D_1=0$.

A “*dummy*” D_1 incorpora o efeito do primeiro dia da semana em que a oficina operou.

Uma das vantagens deste modelo é o facto de poder modelar mais do que uma componente sazonal e, por isso realizou-se uma análise relativa à presença de sazonalidade anual.

Na Figura 4.18 é apresentado o valor médio mensal de utilização de H.h para clientes sem marcação de Fevereiro de 2014 a Março de 2016, onde cada um dos meses contou entre 21 a 22 observações.




Figura 4.18 – Utilização média por mês de H.h para clientes sem marcação entre Fevereiro de 2014 a Março de 2016 na oficina autorizada Soauto Expo.

Fonte: SIVA 2016.

Observa-se na Figura 4.18 picos de utilização no mês de novembro e no mês de junho o que pode indicar que nos meses que antecedem os períodos de férias e de quadra festiva natalícia

existe uma maior procura do serviço de assistência técnica por parte dos clientes, com o objetivo de terem o seu veículo reparado e inspecionado antes destes períodos, que implicam sempre uma grande utilização e longas viagens dos veículos automóveis.

O mês de agosto apresenta, em média, uma quebra de utilização de H.h para clientes sem marcação pelo facto de se encontrarem menos técnicos disponíveis por coincidir com o período de férias da maior parte dos técnicos e por ser um período onde a grande maioria dos clientes recorre ao serviço de assistência técnica das oficinas perto dos seus locais de férias.

Observa-se, também, uma queda de utilização de H.h para clientes sem marcação no mês de maio, por isso considerou-se relevante introduzir este facto no modelo de regressão linear múltipla e analisar o seu impacto.

Portanto, na Tabela 4.9 são consideradas as variáveis “*dummy*” que podem ser importantes e incorporadas no modelo de regressão linear múltipla.

Tabela 4.9 – Variáveis “*dummy*” consideradas no modelo de regressão linear múltipla.

Variáveis “ <i>dummy</i> ” consideradas		
Componente sazonal	Semanal	Segunda-feira
		Terça-feira
		Quarta-feira
		Quinta-feira
		Primeiro dia da semana em que oficina operou
	Anual	Maio
		Junho
		Agosto
		Novembro

iii) Ajustamento do Modelo de Regressão Linear Múltipla

Relativamente ao modelo de regressão linear múltipla, este foi aplicado tendo em conta as variáveis quantitativas e as variáveis “*dummy*” identificadas nos pontos i) e ii) desta secção, com o objetivo de modelar os valores de utilização de H.h para clientes sem marcação com base

na amostra de ajustamento. Os resultados relativos ao ajustamento são apresentados na Tabela 4.10.

A partir do teste à significância dos coeficientes de regressão considerados na análise preliminar resultou a escolha do modelo 2, pois verifica-se que no modelo 1 a variável horas agendadas para dias posteriores e as variáveis “dummy” relativas ao mês de Maio e Agosto têm um *p-value* superior a 0,05, o que significa que os três coeficientes são estatisticamente não significativos. Por isso, retirou-se as três variáveis do modelo 1 uma de cada vez, resultando o modelo 2, do qual se constatou que todos os coeficientes de regressão são significativos exceto a constante.

No entanto, o modelo 2 apenas consegue estimar o valor do dia seguinte devido à variável horas não preenchidas para marcação. Do ponto de vista operacional é pouco viável, pois não contribui para a preparação atempada dos trabalhos da oficina.

Deste modo, estudou-se o modelo 3 que não inclui a variável horas não preenchidas para marcação com objetivo de obter um modelo que consiga fornecer um valor atempado (para daqui a 5 dias ou mais). Como seria de esperar os quatro coeficientes em estudo no modelo 3 são todos significativos.

	Modelo	Coefficientes	Desvio Padrão	Estatística <i>t</i>	<i>p-value</i>
1	(Constante)	3,140	2,201	1,264	0,155
	Horas disponíveis na agenda	0,086	0,024	3,595	$3,8 \times 10^{-04}$
	Horas não preenchidas para marcação	0,065	0,033	1,939	0,053
	Horas agendadas para dias	-0,012	0,010	-1,230	0,220
	Tempo	-0,010	0,003	-3,015	0,003
	Segunda-feira	6,789	1,189	5,710	$2,6 \times 10^{-08}$
	Terça-feira	0,925	1,213	0,762	0,446
	Quarta-feira	0,286	1,216	0,235	0,814
	Quinta-feira	0,258	1,209	0,214	0,831
	Maio	-0,778	1,194	-0,652	0,515
	Junho	3,516	1,189	2,958	0,003
	Agosto	0,074	1,337	0,056	0,956
	Novembro	4,134	1,238	3,339	$9,4 \times 10^{-04}$
	(Constante)	0,894	1,532	0,584	0,560

Tabela 4.10 – Resultados obtidos do ajustamento de 3 modelos de regressão linear múltipla.					$\cdot 10^{-07}$
2	Horas não preenchidas para marcação	0,068	0,021	3,227	0,001
	Tempo	-0,008	0,003	-2,624	0,009
	Primeiro dia da semana	6,344	0,723	8,771	$1,1 \times 10^{-16}$
	Junho	3,399	1,220	2,948	0,003
	Novembro	4,405	1,235	3,608	$3,6 \times 10^{-04}$
3	(Constante)	-0,065	1,525	-0,043	0,966
	Horas disponíveis na agenda	0,122	0,013	9,137	8×10^{-18}
	Tempo	-0,007	0,003	-2,268	0,024
	Primeiro dia da semana	5,963	0,724	8,236	5×10^{-15}
	Junho	2,981	1,162	2,564	0,011
	Novembro	5,097	1,220	4,179	4×10^{-05}

Assim, com base na tabela dos coeficientes e na viabilidade operacional, identifica-se o modelo de regressão linear múltipla na equação (4.8).

$$Y_t = -0,065 - 0,007X_1 + 0,122X_2 + 5,963D_1 + 2,981D_2 + 5,097D_3 \quad (4.8)$$

Onde:

Y_t – Utilização de H.h para clientes sem marcação para o período t ;

X_1 – Tempo. Se se pretende estimar o 1º de utilização de H.h para clientes sem marcação, ou seja, estimar a utilização de H.h para clientes sem marcação para o período $t=1$, então $X_1=1$. Se se pretende estimar a utilização de H.h para clientes sem marcação para o período $t=2$, então $X_1=2$. Se se pretende estimar a utilização de H.h para clientes sem marcação para o período $t=3$, então $X_1=3$. E, assim, sucessivamente para incorporar a influência ténue da tendência negativa.

X_2 – Horas disponíveis na agenda para o período t ;

D_1 – Variável “dummy” relativa ao primeiro dia da semana em que oficina opera. Se se trata de uma previsão para o primeiro dia da semana em que oficina opera $D_1=1$, se não $D_1=0$;

D_2 – Variável “dummy” relativo a junho. Se se trata de uma previsão no mês de junho $D_2=1$, se não $D_2=0$;

D_3 – Variável “dummy” relativo a novembro. Se se trata de uma previsão no mês de novembro $D_3=1$, se não $D_3=0$;

Nas Tabelas 4.11, 4.12 e 4.13 encontram-se os resultados da precisão do modelo 3 obtido para a amostra de ajustamento, respetivamente, à análise da variância (ANOVA), às estatísticas do erro e do R^2 , e ao teste *Bias* ao EM.

Tabela 4.11 – Análise da variância do modelo de regressão linear múltipla (modelo 3).

	gl	SQ	MQ	Rácio F	F de significância
Regressão	4	5905,29	181,06	43,75	$2,58 \times 10^{-34}$
Erro	321	8639,43	27,00	-	-
Total	325	14544,73	-	-	-

A Tabela ANOVA permite confirmar que os 5 coeficientes de regressão influenciam significativamente a variável dependente, utilização de H.h para clientes sem marcação.

Tabela 4.12 – Resultados obtidos do ajuste do modelo de regressão linear múltipla (modelo 3).

Estatísticas			Resultados
Amostra	DPA (H.h)		6,690
Modelo	Estatísticas de erro	EM (H.h)	0,029
		DMA (H.h)	4,119
		REQM (H.h)	5,140
		EPAM	51%
		R^2	41%

Tabela 4.13 – Teste do *Bias* ao erro médio (Regressão linear múltipla, modelo 3; etapa de ajustamento).

	$ Z_{calculado} $	$ Z_{0,05} $	
Teste do <i>Bias</i> ao EM	0,103	1,645	Não se encontra enviesado

Os resultados das estatísticas do erro de previsão mostram um EM não enviesado e a redução das estatísticas residuais face aos modelos obtidos com base no horizontal temporal e nos erros de previsão (AES com sazonalidade, *Holt-Winters* e SARIMA).

O modelo de regressão linear múltipla apresenta uma capacidade preditiva média-baixa, conseguindo modelar 41% da variabilidade de utilização de H.h para clientes sem marcação da amostra de ajustamento. Contudo, este modelo apresenta maior capacidade para modelar a variabilidade presente nos dados, pois cerca de 17% da variabilidade é explicada pela influência das horas disponíveis na agenda. Ou seja, é introduzida a influência da fase 1 (definição de objetivos) do agendamento dos trabalhos da oficina. Os restantes 24% são explicados pelo horizonte temporal e pelas componentes sazonais semanal e anual.

Resumindo, o modelo de regressão linear múltipla analisado (modelo3) não estima valores tendo em conta a magnitude do erro de previsão e não se limita apenas a modelar o horizonte temporal e a componente sazonal. Portanto, incorpora também a influência do agendamento dos trabalhos da oficina e dos feriados (valores nulos), que se traduz num estudo mais rigoroso da evolução da utilização de H.h para clientes sem marcação. No entanto, na Figura 4.19 observam-se valores extremos da amostra de ajustamento cujo modelo não consegue modelar adequadamente, daí a estatística do EPAM ser algo elevada e estes valores provocarem um aumento significativo das restantes estatísticas do erro que, por consequência, levam à redução da estatística R^2 .




Figura 4.19 – Valores reais da amostra de ajustamento e valores estimados pelo modelo regressão linear múltipla (modelo 3).

4.6. Etapa de Validação

De acordo com os resultados obtidos na etapa de ajustamento, o modelo AES com sazonalidade apresenta um ajustamento muito baixo pelo que, sendo pouco preciso não será considerado em análises subsequentes. Os modelos SARIMA e *Holt-Winters* têm um ajustamento baixo, mas muito semelhante. Contudo, a complexidade do modelo SARIMA em relação ao modelo *Holt-Winters* permite considerar o modelo de *Holt-Winters*, em detrimento do modelo na etapa de validação. Assim, apenas o modelo de regressão linear múltipla e o modelo de *Holt-Winters* serão validados, de modo a averiguar o seu comportamento fora da amostra de ajustamento (isto é, perante a amostra de validação).

Na validação, foram previstos os valores de utilização de H.h para clientes sem marcação para o intervalo de tempo da amostra de validação, com base nas equações dos modelos ajustados i) regressão linear múltipla e ii) *Holt-Winters*, respetivamente as equações (4.5) e (4.2). Depois realizou-se uma análise comparativa dos valores previstos com os da amostra de validação.

4.6.1. Modelo de Regressão Linear Múltipla

Através da equação (4.8) definida na etapa de ajustamento foram previstos os valores de utilização de H.h para o intervalo de tempo da amostra de validação. Depois foi feita uma análise comparativa destes valores com os da amostra de validação. As Tabelas 4.14 e 4.15 apresentam os resultados obtidos da precisão dos valores de previsão (previstos pelo modelo) comparativamente aos valores reais (amostra de validação).

Tabela 4.14 – Resultado da capacidade preditiva do modelo de regressão linear múltipla (modelo 3) para a amostra de validação.

	$Z_{calculado}$	$ Z_{0,05} $	
Teste do Bias ao EM	1,515	1,645	Não se encontra enviesado

Tabela 4.15 – Teste do Bias ao erro médio (Regressão linear múltipla, modelo 3; etapa de validação).

Pela observação dos resultados das Tabelas 4.14 e 4.15 pode-se verificar que o modelo não se encontra enviesado e que reduziu a sua capacidade preditiva, conseguindo modelar apenas 19% da variabilidade presente na amostra de validação, segundo a estatística R^2 . Na Figura 4.20 é possível observar que a amostra de validação não apresenta em certos períodos a influência sazonal semanal que se observou na amostra de ajustamento e que o modelo apresenta certas limitações

	Estatísticas		Resultados	
Amostra	DPA (H.h)		5,334	
		EM (H.h)	-1,067	
Modelo	Estatísticas de erro	EAM (H.h)	3,624	
		REQM (H.h)	4,619	
		EPAM	35%	
		R^2	19%	

como facto de pequenas variações entre os previstos, o que contribui para a estatística R^2 sofresse uma redução.




Figura 4.20 – Valores reais da amostra de validação e valores previstos pelo modelo de regressão linear múltipla (modelo 3).

4.6.2. Modelo de Holt-Winters

Com base na equação (4.2) definida na etapa de ajustamento foram previstos os valores de utilização de H.h para o intervalo de tempo da amostra de validação e, posteriormente, efetuou-se uma análise comparativa destes valores com os da amostra de validação. As Tabelas 4.16 e 4.17 apresentam os resultados obtidos da precisão dos valores de previsão (previstos pelo modelo) comparativamente aos valores reais (amostra de validação).

Tabela 4.16 – Resultados obtidos da aplicação do modelo Holt-Winters na amostra de validação.

Estatísticas		Resultados	
Amostra	DPA (H.h)	5,334	
Modelo	Parâmetros	α =0,099; β =0; γ =0,119	
	Estatísticas de erro	EM (H.h)	0,117
		EAM (H.h)	3,389
		REQM (H.h)	4,307
		EPAM	36%
	R^2	55%	

Tabela 4.17 – Teste do Bias ao erro médio (Holt-Winters; etapa de validação).

	$ Z_{calculado} $	$ Z_{0,05} $	
Teste do Bias ao EM	0,168	1,645	Não se encontra enviesado

Com a observação dos resultados das Tabelas 4.16 e 4.17 pode-se verificar que o modelo não se encontra enviesado. Apesar da amostra de validação não apresentar em certos períodos a influência sazonal semanal que se observou na amostra de ajustamento, o modelo reduziu ligeiramente o EM, o EAM e a REQM, comparativamente ao modelo de regressão linear múltipla, e apresentou uma capacidade preditiva média, conseguindo modelar 55% da variabilidade

presente nos dados, segundo a estatística R^2 . No entanto, apresenta um EPAM ligeiramente mais elevado que o modelo de regressão linear múltipla.

Na Figura 4.21, relativa aos desvios entre os valores reais e os previstos, verifica-se que o modelo apresenta capacidade para modelar o nível, o que contribui para o aumento da estatística R^2 .




Figura 4.21 – Valores reais da amostra de validação e valores previstos pelo modelo Holt-Winters ($\alpha = 0,099$; $\beta = 0$; $\gamma = 0,119$).

4.7. Avaliação dos Modelos

O principal objetivo da avaliação dos modelos desenvolvidos, em resultado do estudo realizado na empresa, centrou-se em analisar a capacidade preditiva de cada um dos modelos, ou seja, em analisar o desvio (erro de previsão) entre a capacidade dos modelos preverem a necessidade diária de utilização de H.h para clientes sem marcação e a utilização diária de H.h que realmente ocorreu (para clientes sem marcação).

A Tabela 4.18 apresenta a estatística R^2 , a REQM e o EPAM obtidos após o ajustamento dos modelos (usando consequentemente a amostra de ajustamento), bem como o alcance de previsão. Por definição, é desejado que o valor obtido para a estatística R^2 seja o mais elevado possível e que os valores obtidos de REQM e EPAM sejam o mais reduzidos possível. Do ponto de vista operacional, é desejado um modelo que minimize os desvios e apresente um bom alcance de previsão, para que permita auxiliar atempadamente o planeamento para o dia em causa.

Tabela 4.18 – Quadro síntese dos resultados obtidos na etapa de ajustamento e o alcance de previsão em cada um dos modelos estudados.

Modelo	Estatística R^2		REQM	EPAM	Alcance de previsão
	Ajustamento	Classificação de ajustamento			

Regressão Linear Múltipla (modelo 3)	41%	Médio	5,140	51%	Consoante o pretendido
SARIMA	29 %	Baixo	5,561	53%	1 dia
<i>Holt-Winters</i>	30 %	Baixo	5,869	58%	1 dia
AES e sazonalidade	17 %	Baixo	6,072	65%	5 dias

Como é possível verificar pelos resultados presentes na Tabela 4.18, o modelo que revela maior rigor em relação às suas estimativas e maior alcance de previsão é o modelo de regressão linear múltipla. Um dos aspetos positivos do modelo de regressão linear múltipla é que incorpora a influência do agendamento dos trabalhos da oficina para além da influência do tempo, nomeadamente, da tendência negativa e dos comportamentos sazonais semanal e anual. No entanto, apresenta limitações como o facto de não modelar adequadamente os valores mais elevados de utilização e de revelar pequenas variações entre os valores estimados para os diversos dias da semana.

A partir dos resultados obtidos na etapa de ajustamento, o modelo AES com sazonalidade apresenta um ajustamento muito baixo pelo que, sendo pouco preciso não será considerado em análises subsequentes. Os modelos SARIMA e *Holt-Winters* têm um ajustamento baixo, mas muito semelhante. Contudo, a complexidade do modelo SARIMA em relação ao modelo *Holt-Winters* permite considerar o modelo de *Holt-Winters*, em detrimento do modelo na etapa seguinte. Assim, apenas o modelo de regressão linear múltipla e o modelo de *Holt-Winters* serão validados, de modo a averiguar o seu comportamento fora da amostra de ajustamento (isto é, perante a amostra de validação).

Na etapa de validação, o modelo de *Holt-Winters* apresentou maior capacidade preditiva, de acordo com a estatística R^2 , e uma REQM mais reduzida, comparativamente ao modelo de regressão linear múltipla. O modelo de regressão linear múltipla diminuiu a sua capacidade preditiva. Isto pode ter sido devido ao facto de se tratar de uma previsão diária e de o modelo revelar pequenas variações entre os valores estimados e, ainda, pelo facto da amostra de validação não apresentar aparentemente o mesmo comportamento sazonal em termos semanais da amostra de ajustamento. A Tabela 4.19 apresenta os resultados obtidos na etapa da validação.

Tabela 4.19 – Quadro síntese dos resultados obtidos na etapa de validação para os modelos de regressão linear múltipla e *Holt-Winters*..

Modelo	Estatística R^2	REQM	EPAM
	Validação		

Regressão Linear Múltipla (modelo 3)	19%	4,619	35%
<i>Holt-Winters</i>	55%	4,307	36%

De acordo com as etapas de ajustamento e de validação, pode-se concluir que é o modelo de *Holt-Winters* o que apresenta maior capacidade de reduzir a dimensão dos desvios (erro de previsão) entre a utilização diária real e a previsão da utilização diária para clientes sem marcação.

Nesse sentido adicionou-se o objetivo seguinte, avaliar se o modelo de *Holt-Winters* estudado alcança melhores resultados do que a política de agendamento que atualmente se encontra em vigor para a oficina autorizada Soauto Expo, a qual define a utilização diária de H.h para clientes sem marcação com base na equação (4.9), mencionada teoricamente na secção 3.2.1.1.

$$Y_t = (T_t + P_t) - A_t \quad (4.9)$$

Onde:

Y_t – Utilização de H.h para clientes sem marcação para o período t ;

T_t – Número (objetivo) de horas a trabalhar para o período t ;

P_t – Número de horas previstas (previsão subjetiva) de faltas de clientes com marcação para o período t ;

A_t – Número (objetivo) de horas a agendar para o período t .

No entanto, verificou-se que no intervalo de tempo dos dados recolhidos (14 de fevereiro de 2014 a 31 de Maio de 2016) não houve registo do número de horas previstas de faltas de clientes com marcação (P_t). Deste modo, a utilização diária de H.h para clientes sem marcação é definida apenas pela diferença entre o objetivo de horas a trabalhar (T_t) e o objetivo de horas a agendar (A_t) estabelecidos diariamente – com base na política de agendamento atualmente em vigor.

A Tabela 4.20 apresenta os resultados obtidos em relação às estatísticas do erro quer da metodologia estudada quer da metodologia atualmente em vigor para o intervalo de tempo da amostra de validação.

Tabela 4.20 – Resultados na etapa de validação: Metodologia de agendamento proposta vs. Metodologia de agendamento atual.

Metodologia de agendamento (para definição da utilização diária de H.h para clientes sem marcação)	EM	EA	EAM	REQM	EPAM
Proposta (com implementação do modelo de <i>Holt-Winters</i>)	0,117	145,724	3,389	4,307	36%
Política de agendamento atualmente em vigor	9,753	425,420	9,893	5,106	44%

Segundo a Tabela 4.20, a metodologia de agendamento proposta com base no modelo de *Holt-Winters* apresenta maior rigor do que a atual metodologia. Os valores das estatísticas do erro de previsão obtidos através da metodologia proposta são significativamente menores que os da metodologia atual. A partir da soma dos erros absolutos (EA) pode-se constatar que o número de horas perdidas, resultante tanto de improdutividade (com a previsão acima do real) como de atraso nos trabalhos definidos (com a previsão abaixo do real), usando a metodologia proposta reduziu 280 H.h ($425,420 - 145,724 \approx 280$ H.h) face à metodologia de agendamento atual, no intervalo de tempo da amostra de validação.

Deste modo, a metodologia de agendamento proposta usando o modelo de *Holt-Winters* no âmbito da gestão das operações diária das oficinas autorizadas pela empresa deve ser alvo de uma investigação futura, no sentido de melhorar a sua capacidade preditiva pois, a sua implementação, pode tornar mais eficientes e eficazes as operações diárias das oficinas autorizadas pela empresa.

4.8. Proposta de Metodologia de Apoio ao Agendamento de uma Oficina

Após realização da análise de sensibilidade na secção 4.7. observou-se que a metodologia de apoio ao agendamento das operações de mecânica da oficina Soauto Expo potencia a eficácia de agendamento e eficiência das operações diárias.

Assim, na Tabela 4.21 são apresentados os passos para a implementação da metodologia proposta numa oficina de reparação automóvel que se pretenda guiar por este método de organização/agendamento das operações de mecânica.

Tabela 4.21 – Metodologia de apoio ao agendamento das operações de mecânica de uma oficina de reparação automóvel - Proposta

Ajustamento do Modelo	1. Extração de dados	<p>Extrair os dados de utilização de H.h para clientes sem marcação referentes aos dados do ano mais recente, extraíndo-os para uma folha de Excel, ou seja, estando no dia anterior ao dia que se pretende efetuar a previsão recolhe-se os dados históricos de 1 ano até à véspera do dia da previsão, de modo a identificar e captar certos comportamentos de utilização de horas-homem para clientes sem marcação.</p>	
	2. Tratamento de Dados	<p>Tratamento de valores nulos e <i>outliers</i>. Para a deteção de <i>outliers</i> pode-se utilizar o teste <i>box-plot</i> apresentado na secção 2.3.4.2.</p> <p>Substituir os valores nulos e <i>outliers</i> pela média entre o valor de utilização de H.h para clientes sem marcação do período homólogo anterior e do período homólogo posterior.</p>	
	3. Análise de Padrões	3.1. Presença de tendência	Averiguar através da Regressão da análise de dados do Excel se a tendência é significativa.
		3.2. Presença de sazonalidade semanal	Averiguar através da FAC ou de um modo menos complexo através do gráfico da utilização média mensal de H.h para clientes sem marcação com segmentação por dias da semana (Seg, Ter, Qua, Qui e Sex).
	4. Ajustamento do Modelo de Holt-Winters	4.1. Inicialização do nível	$L_5 = \frac{1}{5}(Y_1 + Y_2 + Y_3 + Y_4 + Y_5)$ <p>Os primeiros 5 valores do nível são definidos pela equação acima. Seja Y a utilização de H.h para clientes sem marcação.</p>
		4.2. Inicialização da tendência	$T_5 = \frac{1}{5} \left[\frac{Y_{5+1} - Y_1}{5} + \frac{Y_{5+2} - Y_2}{5} + \dots + \frac{Y_{5+5} - Y_5}{5} \right]$ <p>Os primeiros 5 valores da tendência são definidos pela equação acima.</p>
		4.3. Inicialização dos índices sazonais	$S_1 = \frac{Y_1}{L_5}, S_2 = \frac{Y_2}{L_5}, S_3 = \frac{Y_3}{L_5}, S_4 = \frac{Y_4}{L_5}, S_5 = \frac{Y_5}{L_5}$ <p>Os primeiros 5 valores dos índices sazonais são definidos pelas equações acima.</p>
		4.4. Ajustamento	<p>i) Estimativa do nível: $L_t = \alpha \frac{Y_t}{S_{t-5}} + (1 - \alpha)(L_{t-1} + T_{t-1})$</p> <p>ii) Estimativa da tendência: $T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$</p> <p>iii) Estimativa da sazonalidade: $S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-5}$</p> <p>iv) Previsão: $P_{t+1} = (L_t + T_t)S_{t-5+1}$</p> <p>Os restantes valores do nível, da tendência, da sazonalidade e ajustados (Previsão) são calculados pelas equações acima.</p>

		4.5. Determinação das constantes de alisamento	Recorrer à função Solver do Excel para otimizar as três constantes de alisamento associadas ao modelo, α , β e γ , tendo como função objetivo a minimização da REQM e como restrições cada uma das constantes ser não negativa e inferior ou igual a 1 ($0 \leq \alpha \leq 1 \wedge 0 \leq \beta \leq 1 \wedge 0 \leq \gamma \leq 1$).
		4.6. Avaliação da qualidade de ajustamento	Quantificar e avaliar as estatísticas do erro de previsão, nomeadamente, EM, EAM, REQM, EPAM e R^2 .
Previsão	5. Previsão da Folga	Previsão: $P_{t+p} = (L_t + pT_t)S_{t-5+p}$ Em que p é o horizonte temporal para o qual se pretende efetuar a previsão.	
Definição dos Restantes Objetivos	6. Definição do Número de H.h Disponíveis	$\sum_{j=1}^n \text{Número de horas disponíveis}_j$ Em que n é o número de técnicos disponíveis para o dia i .	
	7. Cálculo do Objetivo de Horas a Trabalhar	$\text{Objetivo de Horas a Trabalhar}_i = 0,95 \times \text{Número de H. h Disponíveis}_i$ Em que i o dia/período i .	
	8. Cálculo do Objetivo de Horas a Agendar	$\text{Objetivo de Horas a Agendar}_i = \text{Objetivo de Horas a Trabalhar}_i - \text{Previsão da folga}_i$ Em que i o dia/período i .	

É de salientar que só é possível proceder às etapas a seguir à etapa 3 (Análise de Padrões) se se verificar a presença de tendência e sazonalidade semanal.

Com vista ao ajustamento periódico do modelo de *Holt-Winters* recomenda-se que para uma constante de alisamento, β :

- $\beta \approx 0$, o ajustamento do modelo deve ser feito semanalmente (de 5 em 5 dias);
- β pouco reativo ($0 < \beta < 0,5$), o ajustamento do modelo deve ser feito mês a mês;
- β muito reativo ($0,5 < \beta < 1$), o ajustamento do modelo deve ser feito quadrimestralmente.

Relativamente à definição dos restantes objetivos para cada dia, esta é realizada tendo em conta a Tabela 4.21 e a Figura 4.2.

Esta metodologia deve ser monitorizada através dos indicadores de desempenho diários, nomeadamente, a taxa de ocupação, a taxa de utilização para cada tipo de estado e a eficácia de agendamento, sendo estes mencionados e definidos na secção 3.2.3.

Capítulo 5 – Conclusões e Propostas para Desenvolvimento Futuro

Este é o Capítulo final desta dissertação, onde é efetuada uma descrição sucinta do estudo desenvolvido e das principais conclusões obtidas nos diversos capítulos. Apresentam-se, ainda, as limitações dos modelos utilizados e, por fim, as recomendações para ações de controlo e de melhoria e as propostas de trabalho futuro neste âmbito.

5.1. Principais conclusões

5.1.1. Importância do Agendamento

Uma parte importante desta dissertação compreendeu a contextualização do estudo, dando enfoque no agendamento dos trabalhos diários de uma oficina de reparação e manutenção automóvel e da melhoria do planeamento. Desta contextualização evidenciam-se as seguintes conclusões:

- O agendamento dos trabalhos a serem realizados permite i) um planeamento rigoroso das necessidades de recursos, principalmente humanos, e da disponibilidade destes para satisfazer a procura não planeada; ii) planear a chegada de peças no momento certo e nas quantidades certas para as intervenções de reparação, manutenção e substituição, proporcionando uma melhor gestão de *stock* das peças de substituição; iii) assegurar atempadamente a disponibilidade dos equipamentos e das instalações; e iv) programar as atividades de reparação/manutenção para um determinado dia;
- A melhoria do agendamento, nomeadamente da sua eficácia, promove o aumento da rentabilidade da empresa através i) da diminuição de improdutividades, ii) do aproveitamento máximo do número de horas disponíveis dos técnicos para faturar e iii) da redução de custos com a melhoria da gestão dos seus recursos. A melhoria do agendamento contribui, também, para o aumento da satisfação do cliente.

5.1.2. Desempenho Atual da Oficina em Estudo

Antes da realização do estudo no sentido de avaliar e propor uma alteração na metodologia de agendamento das operações diárias de mecânica da oficina com o objetivo de melhorar o desempenho do serviço de assistência técnica, foi fundamental nesta dissertação, medir, analisar e avaliar o desempenho oficial para identificar os aspetos críticos e as oportunidades de melhoria.

Deste modo, considerou-se três indicadores de desempenho que se consideram importantes associados ao rendimento operacional do serviço, nomeadamente:

- i) Taxa de ocupação;
- ii) Taxa de utilização para cada tipo de “estado”;
- iii) Eficácia da marcação.

A partir da monitorização do desempenho das atividades diárias da oficina Soauto Expo destacam-se as seguintes conclusões:

- A ocupação média mensal, por norma, apresenta um valor superior, ou aproximadamente igual, à ocupação média das indústrias europeias (que corresponde a 90%). No entanto, nos meses de outubro e novembro registaram-se valores médios de ocupação inferiores à média europeia, ou seja, com uma percentagem considerável de tempos não produtivos, devido à elevada ocorrência de excesso de agendamentos nesses períodos;
- Pela taxa de utilização média mensal, verificou-se que apenas 33% (valor médio) das horas atribuídas aos técnicos correspondem a trabalho agendado para clientes com marcação – agendadas M –, existindo uma elevada utilização para ordens de reparação pendentes que não são agendadas com antecedência – extra O –, 45% (valor médio). Observou-se, também, que as ordens de reparação pendentes não são agendadas previamente, resultando em registo de trabalho nulo realizado neste “estado” – agendadas O. Em média, cerca de 13% das horas atribuídas aos técnicos são utilizadas para clientes sem marcação – extra M –, observando-se picos de utilização média nos meses de junho e novembro. Os restantes 9% (valor médio) correspondem a improdutividades, ou seja, à percentagem de horas atribuídas aos técnicos associada a atividades não produtivas;
- Pela taxa de utilização média diária, verificou-se que à segunda-feira existe uma maior utilização das horas disponíveis para clientes sem marcação e à sexta-feira com o reduzido trabalho que é planeado previamente implica que haja uma maior percentagem de improdutividade.

5.1.3. Metodologia Proposta e o Caso de Estudo

A metodologia de apoio ao agendamento proposta é aplicada na 1ª fase do agendamento (definição de objetivos) e tem como objetivo definir diariamente o número de horas i) a trabalhar, ii) a agendar e iii) de trabalho não agendado/planeado. O número de horas a trabalhar está previamente definido, como sendo 95% do número de horas disponíveis na agenda. Subsequentemente estabelece-se o número de horas a agendar para o dia, a partir da diferença entre o número de horas a trabalhar e o número de horas de trabalho não agendado/planeado. O número de horas de trabalho não agendado/planeado é obtido através de uma previsão quantitativa

assente num modelo de previsão capaz de contemplar as necessidades diárias de utilização de horas-homem para clientes sem marcação prévia (isto é, horas atribuídas aos técnicos que são utilizadas para trabalho não agendado/planeado).

Com a metodologia de agendamento proposta pretende-se melhorar o agendamento e, consequentemente tornar mais eficientes e eficazes as operações diárias da oficina autorizada Soauto Expo.

Assim, com a metodologia de agendamento proposta e a sua aplicação num caso de estudo, destacam-se as seguintes conclusões:

- A utilização de um modelo de previsão na 1ª fase do agendamento (Definição de objetivos) – segundo a metodologia de agendamento proposta – permite estabelecer, diariamente, o número de horas disponíveis dos técnicos que podem ser dedicadas a trabalhos que não é possível planear, com base nos dados históricos da utilização diária de horas-homem para clientes sem marcação. Este modelo de previsão tem como objetivo auxiliar, com maior rigor, a central de marcações e o gestor após venda do concessionário Soauto Expo, na definição do objetivo de horas a agendar para o dia – para pedidos de clientes a solicitar reparação/manutenção dos seus veículos e para ordens de reparação pendentes na oficina – (Figura 4.2 do Capítulo 4);
- A análise preliminar dos dados históricos, para identificar o comportamento da variável utilização diária de H.h para clientes sem marcação ao longo do tempo, permitiu concluir que existe uma grande variabilidade, uma ligeira tendência negativa e uma influência sazonal semanal (valores mais elevados de utilização no primeiro dia da semana de trabalho);
- Com base na análise preliminar dos dados históricos e de modo a identificar o modelo de previsão que melhor se ajusta ao comportamento da variável, foi adotada uma política de estudo de vários modelos de séries temporais e causais, nomeadamente, alisamento exponencial simples com sazonalidade, *Holt-Winters*, ARIMA e regressão linear múltipla;
- Na etapa de ajustamento, o modelo de regressão linear múltipla (modelo 3) revelou ter um maior rigor nas suas estimativas, apresentando as estatísticas do erro de previsão mais reduzidas, como o erro percentual absoluto médio e a raiz do erro quadrático médio, e uma capacidade preditiva média, conseguindo modelar 41% do comportamento da variável em estudo. No entanto, o modelo apresenta certas limitações como o facto de não modelar adequadamente os valores mais elevados da variável em estudo e de revelar pequenas variações entre os valores estimados;
- No sentido de análises subseqüentes, concluiu-se com a etapa de ajustamento que o modelo de alisamento exponencial simples com sazonalidade apresenta um ajustamento muito baixo pelo que, sendo pouco preciso não foi considerado. Os modelos SARIMA e

Holt-Winters tiveram um ajustamento baixo, mas muito semelhante. Contudo, a complexidade do modelo SARIMA em relação ao modelo *Holt-Winters* permitiu considerar o modelo de *Holt-Winters*, em detrimento do modelo na etapa de validação. Assim, apenas o modelo de regressão linear múltipla e o modelo de *Holt-Winters* foram validados, de modo a averiguar o seu comportamento fora da amostra de ajustamento, isto é, perante a amostra de validação;

- Na etapa de validação, o modelo de *Holt-Winters* revelou ter uma maior capacidade preditiva, apresentando as estatísticas do erro médio e da raiz do erro quadrático médio mais reduzidos, e uma capacidade preditiva média, conseguindo modelar 55% do comportamento da variável em estudo. O modelo de regressão linear múltipla diminuiu a sua capacidade preditiva, conseguindo modelar apenas 19%. Isto pode ter sido devido ao facto de se tratar de uma previsão diária e de o modelo revelar pequenas variações entre os valores estimados e, ainda, pelo facto da amostra de validação não apresentar aparentemente o mesmo comportamento sazonal em termos semanais da amostra de ajustamento;
- Com as etapas de ajustamento e de validação, pode-se concluir que o modelo que apresenta maior capacidade para reduzir os erros de previsão face à variação diária de utilização de horas-homem para clientes sem marcação é o modelo de *Holt-Winters*;
- No entanto, o modelo de *Holt-Winters* apresenta certas limitações como facto de modelar apenas uma componente sazonal;
- Após uma análise de sensibilidade, a metodologia de agendamento proposta com a implementação do modelo de *Holt-Winters* apresentou maior rigor nas suas estimativas e uma redução das estatísticas do erro de previsão face à metodologia de agendamento atualmente em vigor na oficina Soauto Expo. Verificou-se a redução do total da magnitude do erro de previsão (EA) em 280 H.h face à atual metodologia, para a amostra de validação. Este facto significa a redução do número de horas perdidas em improdutividade (quando a previsão se encontra acima do real) e em resultado do atraso nos trabalhos definidos (quando a previsão se encontra abaixo do real).

5.2. Propostas para Desenvolvimento Futuro

Para desenvolvimentos futuros destacam-se algumas recomendações e propostas relativamente:

- Ao modelo de *Holt-Winters* validado:
 - Deve ser objeto de um acompanhamento contínuo no sentido de melhorar o seu desempenho, sempre que possível;

- Os coeficientes associados às variáveis do modelo devem ser atualizados/ajustados periodicamente para manter o rigor na sua estimativa;
- Caso se pretenda aplicar o modelo às restantes oficinas autorizadas pela marca recomenda-se uma análise preliminar para identificar as componentes temporais modeladas pelo modelo – tendência e sazonalidade semanal. Caso estejam presentes as componentes na utilização de horas-homem para clientes sem marcação, pode-se considerar a implementação do modelo com vista a tornar mais eficientes e eficazes as operações diárias das oficinas autorizadas.
- Ao modelo de regressão linear múltipla (modelo 3) estudado:
 - No sentido de melhorar o desempenho do modelo propõe-se um estudo que inclua o impacto de outras variáveis no modelo, designadamente o volume de trabalho pendente na oficina e a atividade promocional do serviço.
- À metodologia de agendamento proposta:
 - Propõe-se a inserção das ordens pendentes de reparação nos objetivos de horas a agendar, de modo a programar atempadamente as atividades para que não haja atraso das restantes ordens de reparação.
- A trabalhos futuros no âmbito da aplicação das técnicas de previsão:
 - Considera-se que seria interessante a utilização de modelos de previsão não lineares baseados em redes neurais e o estudo da sua viabilidade operacional.

Referências Bibliográficas

- Abraham, B. & Ledolters J. (1983). *Statistical Methods for Forecasting*. USA: John Wiley & Sons. [Consulta em junho de 2016]. Disponível em <http://onlinelibrary.wiley.com/doi/10.1002/9780470316610.fmatter/pdf>.
- Adnan, R.; Owens, M. A. & Schwertman, N. C. (2004). “A simple more general boxplot method for identifying outliers” in *Computational Statistics and Data Analysis*. Volume 47, Issue 1. Elsevier. pp. 165-174. [Consulta em maio de 2016]. Disponível em <http://www.sciencedirect.com/science/article/pii/S0167947303002469>.
- Albright S. C.; Winston, W. L. & Zappe, C. (2004). *Analysis for Managers with Microsoft Excel*. 2nd Edition. Belmont: Brooks/Cole-Thomson Learning.
- Armstrong, J. S. (Eds). (2001). *Principles of Forecasting: A Handbook for Researchers and Practitioners (International Series in Operations Research & Management Science)*. [Consulta em junho de 2016]. Disponível em https://books.google.pt/books?hl=pt-PT&lr=lang_en%7Cclang_pt&id=ezTaBwAAQBAJ&oi=fnd&pg=PR5&dq=articles+about+Monitoring+forecast&ots=7DlkVclvc3&sig=Kyt0hn5yZQZ85LzB11By9xHdNgE&redir_esc=y#v=onepage&q=outliers&f=false.
- Athanasopoulos, G. & Hyndman, R. J. (2014). *Forecasting: principles and practice*. Otexts.com. [Consulta em maio de 2016]. Disponível em https://books.google.pt/books?hl=en&lr=lang_en%7Cclang_pt&id=gDuRBAAAQBAJ&oi=fnd&pg=PA7&dq=Principles+of+Forecasting&ots=qJQlftxofD&sig=2aK41o9Icf-Mb9pFNvEBE_90_VY&redir_esc=y#v=onepage&q&f=false.
- Box, G; Jenkins, G. M. & Reinsel, G. (1994). *Time Series Analysis: Forecasting and Control*. Third Edition. New Jersey: Prentice Hall.
- Brebels, A.; Janovsky, T.A.; Kamaev, V.A. Shcherbakov, M.V.; Shcherbakova, N.L. & Tyukov, A.P. (2013) “A Survey of Forecast Error Measures” in *World Applied Sciences Journal n.º 24* (Information Technologies in Modern Industry, Education & Society). pp. 171–176. [Consulta em julho de 2016]. Disponível em [http://www.idosi.org/wasj/wasj\(ITMIES\)13/28.pdf](http://www.idosi.org/wasj/wasj(ITMIES)13/28.pdf).
- Cavalieri, S.; Ierace, S. & Legnani, E. (2009). “A framework for the configuration of after-sales service processes” in *Production Planning & Control*, 20:2. pp. 113-124. [Consulta em junho de 2016]. Disponível em <http://dx.doi.org/10.1080/09537280802707522>.

- Chatfield, C. (2001). *Time-series forecasting*. Boca Raton, Flórida: Chapman and Hall/CRC Press.
- Danese, P. & Kalchschmidt, M. (2011), “The role of the forecasting process in improving forecast accuracy and operational performance”. In *International Journal of Production Economics*, Volume 131, Issue 1, pp. 204-214. [consulta junho de 2016]. Disponível em <http://www.sciencedirect.com/science/article/pii/S0925527310003282>.
- Finch, B. J., & Luebbe, R. L. (1995). *Operations management: Competing in a changing environment*. Fort Worth, TX: Dryden Press.
- Fitzsimmons, J. A. & Fitzsimmons, M. J.. (2001). *Service Management: Operations, Strategy, and Information Technology*. Third Edition. Nova Iorque: McGraw-Hill.
- Galloway, R. L. (1996). *Operations Management: The Basics*. International Thomson Business Press [Consulta em junho de 2016]. Disponível em <https://books.google.pt/books?id=hyGPowuUcksC&printsec=frontcover&dq=operations+management&hl=en&sa=X&ved=0ahUKEwj0ucW349fOAhWGWxoKHesqBioQ6AEIKTAC#v=onepage&q=operations%20management&f=false>.
- Goodwin, P. & Lawton R. (1999). “On the asymmetry of the symmetric MAPE”. in *International Journal of Forecasting*. Volume 15. Pp. 405–408. [Consulta em junho de 2016]. Disponível em www.elsevier.com/locate/ijforecast.
- Gorenflo, G. & Moran, J. W. (2010). “The ABCs of PDCA”. *The Public Health Accreditation Board's (PHAB)*. [consulta em junho de 2016]. Disponível em http://www.phf.org/resourcestools/documents/ABCs_of_PDCA.pdf.
- Gounder, A. S.; Kaliyaperumal, S. K. & Manoj Kuppusamy, M. (2015). “Outlier Detection and Missing Value in Time Series Ozone Data”. In *International Journal of Scientific Research in Knowledge*, 3(9). pp. 220-226. [Consulta em maio de 2016]. Disponível em https://www.researchgate.net/publication/283476236_Outlier_Detection_and_Missing_Value_in_Time_Series_Ozone_Data.
- Gurbuz, F.; Ogus, E. & Yazici, A.C. (2007), “Evaluating the Significance Test When the Correlation Coefficient is Different from Zero in the Test of Hypothesis”. In *Communications in Statistics Simulation and Computation*. Volume 36. Taylor & Francis. pp. 847-854. [consulta em junho de 2016]. Disponível em <http://www.tandfonline.com/doi/pdf/10.1080/03610910701418028>.

- Hanke, John E., & Wichern, Dean W. (2009). *Business Forecasting*. Ninth Edition. USA, New Jersey: Prentice Hall.
- Jennings, C. L.; Kulahci, M. & Montgomery, D. C. (2015). *Introduction to Time Series Analysis and Forecasting*. 2nd Edition. USA: Wiley. [Consulta em junho de 2016]. Disponível em https://books.google.pt/books?hl=en&lr=lang_en%7Clang_pt&id=JCFiBwAAQBAJ&oi=fnd&pg=PA572&dq=adjustment+of+the+quality+measures+of+forecast+method&ots=hhkKp_J0Qi&sig=BTVywEwmTsrAcxKoACou-ZJ5HFs&redir_esc=y#v=onepage&q=R-squared&f=false.
- Jornal das Oficinas. (2016, fevereiro). “A agenda da oficina”. [Consulta em março de 2016]. Disponível em <https://www.yumpu.com/pt/document/fullscreen/55065860/jornal-das-oficinas-123>.
- Lagemann, H.; Meier, H.; Morlock, F. & Rathmann, C. (2013). “Key performance indicators for assessing the planning and delivery of industrial services”, 2nd International Through-life Engineering Services Conference. In *Procedia CIRP*. Volume 11. Ruhr-Universität Bochum: Elsevier. pp. 99-104. [consulta em junho de 2016]. Disponível em <http://www.sciencedirect.com/science/article/pii/S2212827113005301>.
- Makridakis, S.; Wheelwright S. C. & Hyndman, R. J. (1998). *Forecasting: Methods and Applications*, Third edition. USA: John Wiley and Sons.
- Pavletic, D.; Pipan, K. K & Sokovic, M. (2010). “Quality Improvement Methodologies – PDCA Cycle, RADAR Matrix, DMAIC and DFSS”. In *Journal of Achievements in Materials and Manufacturing Engineering*, Eslovénia, volume 43, nº 1, pp. 476-483. [consulta em junho de 2016]. Disponível em http://www.journalamme.org/papers_vol43_1/43155.pdf.
- Pellegrini, F. R. (2000). “Metodologia para a implementação de sistemas de previsão de demanda”. Programa de Pós-Graduação em Engenharia de Produção. Universidade Federal do Rio Grande do Sul. Porto Alegre. [Consulta em setembro de 2016]. Disponível em <http://www.producao.ufrgs.br/arquivos/publicacoes/Fernando%20R%20Pellegrini.pdf>.
- Pereira, Z. L. & Requeijo, J. G. (2012). *Qualidade: Planeamento e Controlo Estatístico de Processos*. (2.ª edição). Lisboa: Fundação FCT, UNL.

SIVA. (2016). Programa autodidata de operações de serviço.

Stanković, R.; Velimirović, D. & Velimirović, M. (2011). “*Role and importance of key performance indicators measurement*”. *Serbian Journal of Management*, 6. pp. 63-72. [consulta em junho de 2016]. Disponível em http://www.sjm06.com/SJM%20ISSN1452-4864/6_1_2011_May_1-121/6_1_63-72.pdf.

Wild, R. (2003). *Operations Management (Sixth Edition)*. Thomson Learning. [Consulta em junho de 2016]. Disponível em <https://books.google.pt/books?id=MUPszLJ5aSc&printsec=frontcover&dq=operation+management&hl=en&sa=X&ved=0ahUKEwi27aLO5tfOAhUGB8AKHa34Di4Q6AEITzAJ#v=onepage&q=operation%20management&f=false>.

Outras consultas na Internet:

<http://asq.org/learn-about-quality/continuous-improvement/overview/overview.html>.

<http://www.itl.nist.gov/div898/handbook/prc/section1/prc16.htm>.

Anexos

Anexo I – Tabelas Estatísticas

Tabela I.1 – Valores críticos da distribuição normal reduzida.

Adaptado de: Makridakis *et al.* (1998).

<i>C</i>	<i>p</i>	<i>z</i>	<i>C</i>	<i>p</i>	<i>z</i>
50%	0.25	0.674	96%	0.02	2.054
60%	0.2	0.842	98%	0.01	2.326
70%	0.15	1.036	99%	0.005	2.576
80%	0.1	1.282	99.5%	0.0025	2.807
90%	0.05	1.645	99.8%	0.001	3.090
95%	0.025	1.960	99.9%	0.0005	3.290

Anexo II – Análise de Resultados

Tabela II.2 – Teste Box-plot aplicado aos valores extremos.

Teste Box-plot aplicado aos valores extremos	
Valor mínimo	0,42 H.h
Q_1	8,51 H.h
Mediana	12,07 H.h
Q_3	16,87 H.h
Valor máximo	32,02 H.h
Limite inferior inferior (f_1)	- 8,23 H.h
Intervalo interquartil (IIQ)	8,37 H.h
Limite interior superior (f_3)	33,61 H.h
Considerou-se outlier o valor que $\notin [Q_1 \pm 2 \times IIQ]$	

Tabela II.3 – Teste Box-plot aplicado às diferenças sazonais.

Teste Box-plot aplicado às diferenças sazonais	
Valor mínimo	- 22,27 H.h
Q_1	- 5,21 H.h
Mediana	- 0,16 H.h
Q_3	5,00 H.h
Valor máximo	23,49 H.h
Limite inferior inferior (f_1)	- 25,62 H.h
Intervalo interquartil (IIQ)	10,21 H.h
Limite interior superior (f_3)	25,41 H.h
Considerou-se outlier o valor que $\notin [Q_1 \pm 2 \times IIQ]$	

Estimativas Finais de Parâmetros

Tipo		Coef.	EP de Coef	T	P
MM	1	0,8212	0,0321	25,57	0,000
SMA	5	0,9635	0,0222	43,48	0,000

Diferenciação: 1 regular, 1 sazonal da ordem 5

Número de observações: Série original 326, depois da diferenciação de 320

Resíduos: SQ = 10041,3 (previsões retroativas excluídas)

QM = 31,6 GL = 318

Estatística Qui-Quadrado de Box-Pierce (Ljung-Box) modificada

Lag	12	24	36	48
Qui-Quadrado	12,8	21,9	40,1	54,0
GL	10	22	34	46
Valor-p	0,236	0,467	0,219	0,194

Figura II.1 – Resultados obtidos do ajuste do modelo SARIMA(0,1,1)(0,1,1)₅ à série de ajustamento através do software Minitab.

Estimativas Finais de Parâmetros

Tipo		Coef.	EP de Coef	T	P
AR	1	0,1495	0,0672	2,23	0,027
SAR	5	-0,0588	0,0607	-0,97	0,334
MM	1	0,8780	0,0336	26,13	0,000
SMA	5	0,9623	0,0214	45,06	0,000

Diferenciação: 1 regular, 1 sazonal da ordem 5

Número de observações: Série original 326, depois da diferenciação de 320

Resíduos: SQ = 9840,21 (previsões retroativas excluídas)

QM = 31,14 GL = 316

Estatística Qui-Quadrado de Box-Pierce (Ljung-Box) modificada

Lag	12	24	36	48
Qui-Quadrado	6,8	12,2	31,7	43,2
GL	8	20	32	44
Valor-p	0,557	0,907	0,484	0,506

Figura II.2 – Resultados obtidos do ajuste do modelo SARIMA(1,1,1)(1,1,1)₅ à série de ajustamento através do software Minitab.

Estimativas Finais de Parâmetros

Tipo		Coef.	EP de Coef	T	P
AR	1	0,1790	0,0641	2,79	0,006
MM	1	0,9051	0,0291	31,10	0,000
SMA	5	0,9149	0,0527	17,36	0,000
SMA	10	0,0396	0,0549	0,72	0,472

Diferenciação: 1 regular, 1 sazonal da ordem 5

Número de observações: Série original 326, depois da diferenciação de 320

Resíduos: SQ = 9966,31 (previsões retroativas excluídas)

QM = 31,54 GL = 316

Estatística Qui-Quadrado de Box-Pierce (Ljung-Box) modificada

Lag	12	24	36	48
Qui-Quadrado	10,0	15,9	38,0	49,7
GL	8	20	32	44
Valor-p	0,268	0,722	0,216	0,256

Figura II.3 – Resultados obtidos do ajuste do modelo SARIMA(1,1,1)(0,1,2)₅ à série de ajustamento através do software Minitab.

Estimativas Finais de Parâmetros

Tipo		Coef.	EP de Coef	T	P
AR	1	0,1624	0,0650	2,50	0,013
MM	1	0,8889	0,0306	29,02	0,000
SMA	5	0,9603	0,0229	42,00	0,000

Diferenciação: 1 regular, 1 sazonal da ordem 5

Número de observações: Série original 326, depois da diferenciação de 320

Resíduos: SQ = 9874,30 (previsões retroativas excluídas)

QM = 31,15 GL = 317

Estatística Qui-Quadrado de Box-Pierce (Ljung-Box) modificada

Lag	12	24	36	48
Qui-Quadrado	7,9	13,8	34,5	45,9
GL	9	21	33	45
Valor-p	0,541	0,878	0,398	0,434

Figura II.4 – Resultados obtidos do ajuste do modelo SARIMA(1,1,1)(0,1,1)₅ à série de ajustamento através do software Minitab.